

UNIVERSIDADE FEDERAL DO PARANÁ

SUELLEN RIBEIRO PARDO GARCIA

**MODELAGEM E PREVISÃO DE DESLOCAMENTOS EM BARRAGENS DE
CONCRETO: APLICAÇÃO A DADOS DE INSTRUMENTAÇÃO DA USINA
HIDRELÉTRICA DE ITAIPU**

CURITIBA

2016

SUELLEN RIBEIRO PARDO GARCIA

**MODELAGEM E PREVISÃO DE DESLOCAMENTOS EM BARRAGENS DE
CONCRETO: APLICAÇÃO A DADOS DE INSTRUMENTAÇÃO DA USINA
HIDRELÉTRICA DE ITAIPU**

Tese apresentada ao Programa de Pós-Graduação em Métodos Numéricos em Engenharia na área de concentração em Programação Matemática e na linha de pesquisa em Métodos Estatísticos Aplicados à Engenharia, setores de Tecnologia e Ciências Exatas da Universidade Federal do Paraná, como requisito parcial à obtenção do grau de Doutor.

Orientador: Prof. Dr. Anselmo Chaves Neto.

CURITIBA

2016

G216m

Garcia, Suellen Ribeiro Pardo

Modelagem e previsão de deslocamentos em barragens de concreto:
aplicação a dados de instrumentação da Usina Hidrelétrica de Itaipu / Suellen
Ribeiro Pardo Garcia. – Curitiba, 2016.
109 f. : il. color. ; 30 cm.

Tese - Universidade Federal do Paraná, Setor de Tecnologia e Ciências
Exatas, Programa de Pós-Graduação em Métodos Numéricos em
Engenharia, 2016.

Orientador: Anselmo Chaves Neto .

Bibliografia: p. 93-97.

1. Barragens de Concreto – Brasil. 2. Usina Hidrelétrica – Itaipú (PR). 3.
Barragens de Concreto – Monitoramento. I. Universidade Federal do Paraná.
II. Chaves Neto, Anselmo. III. Título.

CDD: 624.18340981

TERMO DE APROVAÇÃO

Os membros da Banca Examinadora designada pelo Colegiado do Programa de Pós-Graduação em MÉTODOS NUMÉRICOS EM ENGENHARIA da Universidade Federal do Paraná foram convocados para realizar a arguição da Tese de Doutorado de SUELLEN RIBEIRO PARDO GARCIA, intitulada: "Monitoramento de Barragens de Concreto Via Métodos Estatísticos Multivariados: Aplicação a Dados de instrumentação da Usina Hidrelétrica de Itaipu", após terem inquirido a aluna e realizado a avaliação do trabalho, são de parecer pela sua APROVAÇÃO.

Curitiba, 03 de junho de 2016.


ANSELMO CHAVES NETO (UFPR)
(Presidente da Banca Examinadora)


SACHIKO ARAKI LIRA (UFPR)


JAIR MENDES MARQUES (UFPR)


SELMO CHAPIRA KUPERMAN (DESEK - LTDA)


INÁCIO ANDRUSKI GUIMARÃES ((UTFPR – CURITIBA/PR))


CLÁUDIO KRÜGER (UNIVERSIDADE POSITIV)

Curitiba, 03 de junho de 2016

Dedico este trabalho a Deus,
minha fonte de força e perseverança.

Aos meus pais Antônia e Cláudio,
meus maiores incentivadores.

AGRADECIMENTOS

Agradeço a Deus pela minha saúde, pois muitos foram os momentos em que precisei estar bem fisicamente para suportar a rotina de estudos e trabalho. Agradeço também por ter colocado em minha vida pessoas de bom coração, pessoas que doaram seu valioso tempo para me ajudar.

Agradeço ao meu esposo João, por ser paciente e compreensivo em todos os momentos e por compartilhar seus conhecimentos.

Aos meus pais e irmão, Antônio, Cláudio e Rafael, minha eterna gratidão, pois todas as minhas conquistas são fruto do amor e motivação que sempre recebi em “casa”.

Aos meus amados Lara e Abel, por tanto amor e alegria compartilhada.

Agradeço ao meu estimado orientador, Prof. Dr. Anselmo Chaves Neto, pelos ensinamentos, pela disponibilidade, liberdade de opinião, generosidade, por acreditar em minha capacidade e ser sempre um entusiasta.

Ao engenheiro de Itaipu Cláudio Neumann Júnior pela atenção no atendimento presencial e à distância, por suas explicações e correções de texto. Sua participação neste trabalho foi imprescindível.

Aos meus colegas "dinterandos" pelo companheirismo, incentivo e colaboração. Uma turma unida e sempre disposta a ajudar, me sinto honrada por fazer parte dela.

Aos companheiros de viagem Adriana, Dione, Marcos e Rodnny pelas boas risadas e conhecimentos compartilhados.

Às amigas Sheila e Eliete, pela parceria nos trabalhos, pelo auxílio desde o projeto, pela companhia em Curitiba nas longas horas de estudo e também de descontração.

Ao meu amigo Rodnny por estar sempre presente ouvindo os desabafos e motivando-me a continuar. Agradeço também por seus valiosos conhecimentos partilhados durante o curso.

Às amigas Márcia e Jahina pelo apoio, carinho e disponibilidade. Mal posso esperar para retribuir tamanha generosidade.

Agradeço aos colegas de trabalho do Curso de Licenciatura em Matemática da UTFPR do Campus Toledo, pelas palavras de apoio, por me permitirem uma carga horária reduzida de trabalho, por me concederem o último ano com afastamento total de minhas atribuições. Algumas pessoas aqui mereciam um agradecimento especial, mas não citarei nomes, pois posso imperdoavelmente me esquecer de alguém.

RESUMO

Neste trabalho propõe-se uma nova metodologia de previsão para os deslocamentos de um bloco de concreto de uma barragem baseada nas séries históricas dos instrumentos pêndulos direto e invertido instalados no bloco. O método desenvolvido foi aplicado à Barragem de Itaipu. Características dos dados registrados, tais como a autocorrelação, a multicolinearidade e a presença de séries temporais integradas de diferentes ordens foram determinantes para o delineamento da metodologia. A metodologia proposta consiste em ajustar modelos Autorregressivos de Defasagens Distribuídas (ADL) para aplicar a abordagem *Bounds Testing* e assim modelar os deslocamentos horizontais de um bloco de concreto, validar os modelos, realizar as previsões para um horizonte além do observado e construir intervalos de confiança para essas previsões. Os modelos propostos, que são o Modelo de Correção de Erros (ECM) Irrestrito e o Restrito, serão comparados a modelos estatísticos clássicos, tais como modelos Autorregressivos Integrados Médias Móveis (ARIMA) e modelos de Vetores Autorregressivos (VAR). A comparação foi realizada por meio de medidas de avaliação do erro das previsões fora da amostra e avaliação dos gráficos das previsões. Um dos modelos propostos, o ECM irrestrito, apresentou menores medidas de avaliação de erro e o desempenho foi satisfatório na avaliação dos gráficos das previsões fora da amostra. Para cada sensor do pêndulo, foram construídos intervalos de confiança para as previsões do modelo ECM irrestrito, estabelecendo novos limites para as observações de deslocamentos. A metodologia apresentada possui uma configuração inovadora e assim um novo modelo de previsão é inserido na área de monitoramento de barragens de concreto.

Palavras-chave: Monitoramento de Barragens. ADL. Modelo de Correção de Erros. *Bounds Testing*. Previsão. Deslocamentos.

ABSTRACT

This work proposes a new methodology for forecasting the displacement of a concrete block of a dam based on historical series of direct and inverted pendulum installed in the block. The developed method was applied to the Itaipu Dam. Characteristics of recorded data such as the autocorrelation, multicollinearity and the presence of integrated time series of different orders were decisive for the design of the methodology. The proposed methodology consists of: adjusting Autoregressive Distributed Lag models (ADL) and apply the Bounds Testing approach, and thus, modeling the horizontal displacements of a concrete block, validate the models, make forecasts for a horizon beyond the observed and build confidence intervals for these forecasts. The proposed models, which are the Error Correction Model (ECM) Unrestricted and Restricted, will be compared to classic statistical models such as Autoregressive Integrated Moving Average models (ARIMA) and Autoregressive Vectors (VAR). The comparison was performed by evaluation of measurements error of forecasts out-of-sample and evaluation of the graphs of forecasts. One of the proposed models, the unrestricted ECM, showed lower error evaluation measures and its performance was satisfactory in the evaluation of the graphs of out-of-sample forecasts. For each pendulum sensor, confidence intervals were constructed for the predictions of the ECM unrestricted model, setting new limits for observations of displacement. This methodology has an innovative configuration and thus a new forecasting model is inserted into the monitoring field of concrete dams.

Keywords: Monitoring Dams. ADL. Error Correction Model. Bounds Testing.
Forecast. Displacements.

LISTA DE FIGURAS

FIGURA 1 - INSTRUMENTAÇÃO E TIPO DE DETERIORAÇÃO DETECTADA....	22
FIGURA 2 - ESQUEMA DE INSTALAÇÃO DOS PÊNDULOS DIRETO E INVERTIDO.....	24
FIGURA 3 - FOTOGRAFIA AÉREA DA BARRAGEM.....	43
FIGURA 4 - PLANTA DO COMPLEXO ITAIPU.	44
FIGURA 5 - ESQUEMA DE BLOCOS CHAVE NA BARRAGEM DE ITAIPU	45
FIGURA 6 - SEÇÃO DE UM BLOCO DE CONCRETO DO TIPO GRAVIDADE ALIVIADA NO TRECHO F.....	45
FIGURA 7 - REPRESENTAÇÃO DE UM BLOCO CHAVE E INSTRUMENTAÇÃO INSTALADA	46
FIGURA 8 - SENSORES DOS PÊNDULOS CONSIDERADOS PARA ANÁLISE ..	49
FIGURA 9 - METODOLOGIA PROPOSTA.....	51
FIGURA 10 - VARIÁVEIS INDEPENDENTES	58
FIGURA 11 - VARIÁVEIS DEPENDENTES.....	58
FIGURA 12 - RESÍDUOS STUDENTIZADOS DA REGRESSÃO COM A VARIÁVEL PDY	59
FIGURA 13 - PONTOS INFLUENTES NA REGRESSÃO DA VARIÁVEL PIX	60
FIGURA 14 - GRÁFICO DO MODELO ADL NO CONJUNTO DE TREINAMENTO PARA PIX.....	62
FIGURA 15 - PREVISÕES DOS MODELOS PARA O SENSOR PIX (HORIZONTE H=61 DIAS)	68
FIGURA 16 - INTERVALO DE CONFIANÇA PARA AS OBSERVAÇÕES DO SENSOR PIX	68
FIGURA 17 - GRÁFICO DO MODELO ADL NO CONJUNTO DE TREINAMENTO PARA PIY.....	70
FIGURA 18 - PREVISÕES DOS MODELOS PARA O SENSOR PIY (HORIZONTE H=61 DIAS)	72
FIGURA 19 - INTERVALO DE CONFIANÇA PARA AS OBSERVAÇÕES DO SENSOR PIY	73
FIGURA 20 - GRÁFICO DO MODELO ADL NO CONJUNTO DE TREINAMENTO PARA PDX	74

FIGURA 21 - PREVISÕES DOS MODELOS PARA O SENSOR PDX (HORIZONTE H=61 DIAS)	79
FIGURA 22 - INTERVALO DE CONFIANÇA PARA AS OBSERVAÇÕES DO SENSOR PDX.....	79
FIGURA 23 - SÉRIE HISTÓRICA DO SENSOR DO PÊNDULO DIRETO (PDY)	80
FIGURA 24 - GRÁFICO DO MODELO ADL NO CONJUNTO DE TREINAMENTO PARA PDY	82
FIGURA 25 - INTERVALOS DE CONFIANÇA PARA AS PREVISÕES DOS QUATRO MODELOS	86
FIGURA 26 - LIMITES DE ATENÇÃO E DE ALERTA PARA O SENSOR PDY	87
FIGURA 27 - OFFSET ENTRE AS LEITURAS MANUAIS E AUTOMATIZADAS	88
FIGURA 28 - TEMPERATURA AMBIENTE (DESTAQUE NOS PICOS DE INVERNOS DE CADA ANO).....	89
FIGURA 29 - DESLIZAMENTO E TOMBAMENTO EM UM BLOCO DE CONCRETO À GRAVIDADE.....	108
FIGURA 30 - VARIAÇÃO SAZONAL EM UM BLOCO DE CONCRETO À GRAVIDADE	109

LISTA DE QUADROS

QUADRO 1 - DESCRIÇÃO DOS PRINCIPAIS SUBSISTEMAS DE CONTROLE DA SEGURANÇA ESTRUTURAL DA BARRAGEM DE ITAIPU.....	47
---	----

LISTA DE TABELAS

TABELA 1 - ESTATÍSTICAS DESCRITIVAS	60
TABELA 2 - TESTES DE RAÍZES UNITÁRIAS.....	61
TABELA 3 - MODELO ECM IRRESTRITO PARA A VARIÁVEL DEPENDENTE PIX	63
TABELA 4 - MODELO ECM RESTRITO PARA A VARIÁVEL DEPENDENTE PIX ..	65
TABELA 5 - MEDIDAS DE AVALIAÇÃO DOS ERROS.	67
TABELA 6 - MODELO ECM IRRESTRITO PARA A VARIÁVEL DEPENDENTE PIY	70
TABELA 7 - MEDIDAS DE AVALIAÇÃO DOS ERROS.	71
TABELA 8 - MODELO ECM IRRESTRITO PARA A VARIÁVEL DEPENDENTE PDX	75
TABELA 9 - MODELO ECM RESTRITO PARA A VARIÁVEL DEPENDENTE PDX.	76
TABELA 10 - MEDIDAS DE AVALIAÇÃO DOS ERROS.	78
TABELA 11 - MODELO ECM IRRESTRITO PARA A VARIÁVEL DEPENDENTE PDY.....	82
TABELA 12 - MODELO ECM RESTRITO PARA A VARIÁVEL DEPENDENTE PDY	84
TABELA 13 - MEDIDAS DE AVALIAÇÃO DOS ERROS.	85
TABELA 14 - VALORES VIF PARA O MODELO DO SENSOR PIX.....	99
TABELA 15 - VALORES VIF PARA O MODELO DO SENSOR PIY.....	100
TABELA 16 - VALORES VIF PARA O MODELO DO SENSOR PDX.....	100
TABELA 17 - VALORES VIF PARA O MODELO DO SENSOR PDY	101

LISTA DE SIGLAS

ADAS	-	<i>Automatic Data Acquisition System</i>
ADF	-	<i>Augmented Dickey-Fuller</i>
ADL	-	<i>Autoregressive Distributed Lag</i>
AIC	-	<i>Akaike Information Criterion</i>
ANA		Agência Nacional de Águas
AR	-	<i>Autorregressive Model</i>
ARIMA	-	<i>Autoregressive Integrated Moving Average</i>
ARX	-	<i>Autoregressive Exogenous Model</i>
BIC	-	<i>Bayesian Information Criterion</i>
CEASB	-	Centro de Estudos Avançados de Segurança de Barragens
DFFIT	-	<i>Difference in fit value</i>
ECM	-	<i>Error Correction Model</i>
FERC	-	<i>Federal Energy Regulatory Commission</i>
FIS	-	Sistema de Fissuras
GARCH	-	<i>Generalized Autoregressive Conditional Heteroskedasticity</i>
HST	-	<i>Hydrostatic-season-time</i>
HTT	-	<i>Hydrostatic-temperature-time</i>
ICOLD	-	<i>International Commission of Large Dams</i>
LM	-	<i>Lagrange Multiplier</i>
MAE	-	<i>Mean Absolute Error</i>
MAPE	-	<i>Mean Absolute Percent Error</i>
MD	-	Maquete Digital
MS	-	Mapa de Subpressão
MSE	-	<i>Mean Squared Error</i>
RAA	-	Reatividade Álcali-Agregado
RESET	-	<i>Regression Specification Error Test</i>
RMSE	-	<i>Root Mean Squared Error</i>
RNA	-	Redes Neurais Artificiais
RNA-RBF	-	Redes Neurais Artificiais de Funções de Bases Radiais
SAA	-	Sistema Analítico de Auscultação
SAT	-	Sistema de Arquivo Técnico
SGDP	-	Sistema de Gestão de Dados Planimétricos
SGM	-	Sistema de Gestão de Medições Manuais
SR	-	Sistema de Recomendações
SVR	-	<i>Support Vector Regression</i>
VAR	-	<i>Vector Autoregressive</i>
VIF	-	<i>Variance Inflation Factor</i>

SUMÁRIO

1 INTRODUÇÃO	15
1.1 PROBLEMA DE ESTUDO.....	15
1.2 OBJETIVOS	17
1.2.1 Objetivo Geral	17
1.2.2 Objetivos Específicos	18
1.3 JUSTIFICATIVA	18
1.4 ESTRUTURA DO TRABALHO.....	20
2 REVISÃO DA LITERATURA	21
2.1 INSTRUMENTAÇÃO E MONITORAMENTO DE BARRAGENS.....	21
2.2 MODELOS ESTATÍSTICOS NO MONITORAMENTO DE BARRAGENS.....	24
2.3 MODELOS AUTOREGRESSIVOS DE DEFASAGENS DISTRIBUÍDAS	31
2.3.1 Modelo de Correção de Erros (ECM)	31
2.3.2 A Abordagem <i>Bounds Testing</i>	33
2.4 TESTES DE DIAGNÓSTICO DO MODELO.....	35
2.4.1 Teste RESET (<i>Regression Specification Error Test</i>).....	35
2.4.2 Teste de autocorrelação Breusch-Godfrey.....	36
2.5 CONSIDERAÇÕES RELEVANTES PARA FINS DE PREVISÃO	37
3 MATERIAIS E MÉTODOS	43
3.1 USINA HIDRELÉTRICA DE ITAIPU.....	43
3.2 DADOS DA INSTRUMENTAÇÃO NA BARRAGEM DE ITAIPU	46
3.3 MODELAGEM E PREVISÃO	49
3.3.1 Fase 1	51
3.3.2 Fase 2	54
3.3.3 Fase 3	55
4 ANÁLISE E DISCUSSÃO DOS RESULTADOS.....	57
4.1 ANÁLISE UNIVARIADA DOS DADOS	57
4.2 MODELO PARA A VARIÁVEL DEPENDENTE PIX	61
4.2.1 Previsão	66
4.3 MODELO PARA A VARIÁVEL DEPENDENTE PIY	69
4.3.1 Previsão	71
4.4 MODELO PARA A VARIÁVEL DEPENDENTE PDX	73

4.4.1 Previsão	78
4.5 MODELO PARA A VARIÁVEL DEPENDENTE PDY	80
4.5.1 Previsão	85
5 CONCLUSÃO	90
5.1 SUGESTÕES PARA TRABALHOS FUTUROS	91
REFERÊNCIAS.....	93
APÊNDICES	98
APÊNDICE A – TABELAS DOS VALORES VIF.....	99
APÊNDICE B – <i>SCRIPT</i> DO MATLAB.....	102
APÊNDICE C – MODELOS ARIMA E VAR.....	104
MODELOS ARIMA	104
MODELOS VAR	105
APÊNDICE D – COMANDOS NO <i>SOFTWARE</i> EVIEWS	106
APÊNDICE E – MOVIMENTOS NO BLOCO DE CONCRETO À GRAVIDADE	108

1 INTRODUÇÃO

1.1 PROBLEMA DE ESTUDO

As consequências do rompimento de uma barragem são diversas, sendo algumas delas transtornos de caráter social e econômico, danos ao governo, perdas ambientais e especialmente perdas de vidas humanas dos que vivem ou trabalham em áreas a jusante (SERRANO-LOMBILHO, MORALES-TORRES e GARCÍA-KAB, 2012).

O monitoramento de barragens é o principal procedimento usado para a avaliação das condições de segurança. O conhecimento do nível de segurança é importante para a elaboração de um plano de reação a alguma alteração significativa na estrutura (SARÉ *et al.*, 2006).

Segundo Sarmiento e Molina (2014), a postergação ou a não adoção de providências cuja percepção de necessidade é evidenciada pelo monitoramento das barragens, provoca a evolução de situações relativamente comuns de serem solucionadas, para situações mais graves.

As atividades que constituem o monitoramento de barragens são as inspeções visuais regulares e a coleta e análise dos dados da instrumentação, cujo objetivo é identificar eventuais alterações no comportamento observado, gerando alertas para as equipes responsáveis pela gestão da segurança (PENNA, ARAGÃO e FUSARO, 2015).

Quanto à análise de dados da instrumentação, segundo Balbi (2008), a definição de valores de controle para as leituras dos instrumentos pode ser feita através de métodos determinísticos ou estatísticos. Os métodos determinísticos levam em consideração a modelagem numérica da barragem enquanto os estatísticos se baseiam na relação entre as medidas dos instrumentos e outras variáveis, como o nível do reservatório, por exemplo.

Os métodos estatísticos estão associados, basicamente, ao monitoramento realizado na fase de operação, já que verifica ou não mudanças de tendências no comportamento das estruturas, permitindo detectar precocemente alguns problemas. Balbi (2008) ressalta que o fundamental é que os instrumentos possuam níveis de controle estabelecidos de forma adequada ao tipo de monitoramento desejado para permitir análises técnicas mais rápidas e confiáveis.

Alguns fatores monitorados, nas diferentes fases de vida da barragem de concreto são: deslocamentos absolutos, deslocamentos relativos (entre blocos), deformação interna, tensões, pressões intersticiais no concreto, subpressão, vazão de infiltração e temperatura do concreto (ANA, 2015).

Segundo Vasconcelos (1978), os deslocamentos são uns dos parâmetros mais significativos e variam com as condições exteriores como carga e temperatura, entre outros. Os deslocamentos são esperados durante e após a construção. Esses movimentos ocorrem no enchimento do reservatório e conforme seu nível oscila.

Pequenos deslocamentos são de pouco interesse, mas o aumento da magnitude do movimento ou mudança na direção do movimento devem ser avaliados imediatamente quanto ao seu impacto potencialmente negativo sobre a estrutura (AHMADI-NEDUSHAN, 2002).

Os pêndulos direto e invertido são instrumentos que determinam os deslocamentos horizontais da crista da barragem em relação ao ponto considerado fixo na fundação (MATOS, 2002).

Outros fatores muito importantes para a operação dos reservatórios e para a análise do comportamento das estruturas são as variações de níveis d'água a montante e a jusante das estruturas, bem como as precipitações e variações da temperatura ambiente na área do empreendimento (ANA, 2015).

A instrumentação da barragem de Itaipu conta com mais de 2400 instrumentos. As leituras são organizadas em inúmeros gráficos das medições periódicas e uma vez que alguns deles possuem vários locais de leitura, como é o caso do pêndulo direto, a quantidade de gráficos monitorados é ainda maior que o número de instrumentos. De 2005 até a atualidade, os instrumentos que foram automatizados passaram a ter leituras a cada 30 minutos, além das leituras por inspeção visual já existentes desde a época da construção da barragem. Atualmente 10% dos instrumentos instalados na barragem de Itaipu têm suas leituras automatizadas.

Os gráficos das medições periódicas dos instrumentos são monitorados com limites estabelecidos em projeto e com limites baseados em ano anterior. Qualquer mudança no comportamento da barragem detectada por esses limites é investigada com seriedade, mas a questão é: será que esses limites são os ideais para apontar um possível problema na estrutura a tempo de tomar as ações cabíveis? Esses limites

consideram a variação atual de fatores externos como temperatura e nível do reservatório?

Portanto, um modelo para previsão de deslocamentos, mensurados pelos pêndulos direto e invertido, sob efeitos de variação do nível do reservatório e efeitos de variação de temperatura do meio ambiente, pode auxiliar no monitoramento e definir novos limites para as leituras, baseados no relacionamento entre esses fatores desde o estágio de operação normal da barragem até os períodos atuais.

Vários modelos estatísticos para previsão de deslocamentos de barragens de concreto são encontrados na literatura. O modelo *Hidrostatic-season-time* (HST) foi proposto inicialmente em 1958 por Ferry, Will e Beaujoint (CHOUINARD e ROY, 2006), e desde então, algumas versões são encontradas na literatura, como em Ahmadi-Neduchan (2002) e De Sortis e Paoliani (2007). Mata (2011) e Xi *et al.* (2011) propõem aplicação de redes neurais em modelos estatísticos para os deslocamentos horizontais na direção montante-jusante. Enquanto Mata (2011) utiliza o modelo estatístico HST, Xi *et al.* (2011) utiliza o modelo descrito em Léger e Lecler (2007), o *Hydrostatic-temperature-time* (HTT). Li, Wang e Liu (2013) apresenta o modelo HST baseado na teoria de cointegração.

Este trabalho apresenta uma nova metodologia de previsão para os deslocamentos de um bloco de uma barragem de concreto baseada nas séries históricas dos instrumentos pêndulos direto e invertido instalados. Os dados são originários de um bloco de concreto da Barragem de Itaipu. A caracterização dos dados quanto à correlação serial e à presença de séries temporais integradas de diferentes ordens foi determinante para o delineamento da metodologia que possui uma configuração inovadora, por utilizar modelos Autorregressivos de Defasagens Distribuídas (ADL) e a abordagem *Bounds Testing* em dados de monitoramento de barragens de concreto.

A metodologia proposta consiste em ajustar modelos ADL e aplicar a abordagem *Bounds Testing* para análise de cointegração, assim apresentar modelos para deslocamentos horizontais dos pêndulos, validá-los, realizar previsões e construir intervalos de confiança para estas previsões.

1.2 OBJETIVOS

1.2.1 Objetivo Geral

Apresentar uma metodologia inovadora para previsão de deslocamentos de um bloco em barragens de concreto considerando os efeitos de variação do nível do reservatório e efeitos de variação de temperatura do meio ambiente, e assim, auxiliar no monitoramento com a definição de novos limites para as leituras, baseados no relacionamento entre esses fatores.

1.2.2 Objetivos Específicos

Analisar estatisticamente as leituras de cada instrumento individualmente, com o objetivo de identificar possíveis instrumentos defeituosos, leituras erradas e leituras ausentes, bem como identificar *outliers* que possam influenciar o ajuste do modelo.

Ajustar modelos para previsão dos deslocamentos, fazer previsões para as leituras fora da amostra, estabelecer intervalos de confiança para essas previsões.

Estabelecer novos limites para as leituras dos deslocamentos considerando a influência da variação do nível do reservatório e variação da temperatura e, assim, contribuir com o monitoramento da Barragem de Itaipu.

1.3 JUSTIFICATIVA

Modelos estatísticos têm sido amplamente utilizados para prever a resposta de instrumentos de monitoramento de barragens. Tais modelos têm o objetivo de detectar mudanças no comportamento da barragem previamente, permitindo a implementação de medidas corretivas adequadas auxiliando na segurança da obra.

Os modelos são baseados em correlações existentes entre fatores tais como: o nível de água do reservatório, temperatura ambiente, idade da estrutura e a resposta da barragem a estas ações como tensões, deformações e deslocamentos (AHMADI-NEDUSHAN, 2002). Várias aplicações são encontradas na literatura, como por exemplo, em Ahmadi-Nedushan, (2002), Chouinard e Roy (2006), De Sortis e Paoliani (2007), Mata (2011), Xi *et al.* (2011), Li, Wang e Liu (2013).

Existem vários desafios ao se propor tais modelos. Um deles é que as variáveis independentes (variações do nível do reservatório e temperatura) podem, na verdade, guardar dados multicolineares, de modo que não seja possível utilizar algumas técnicas estatísticas clássicas. Outro desafio é a autocorrelação nos dados,

pois geralmente estes são coletados ao longo do tempo, ou seja, existe a possibilidade de autocorrelação temporal. E por fim, as séries temporais podem ser integradas de diferentes ordens e eventualmente cointegradas.

Na tentativa de contornar tais desafios propõe-se o modelo dinâmico Autoregressivo de Defasagens Distribuídas (ADL), cujos regressores incluem valores defasados da variável dependente e valores correntes e defasados das variáveis independentes, considerando autocorrelação nos dados. Os parâmetros são estimados na forma de Bärdsen, uma reparametrização do modelo ADL, atenuando os problemas de multicolinearidade. Por fim, com a abordagem *Bounds Testing* de Pesaran, Shin e Smith (2001) analisa-se a existência de cointegração, ou não, entre as séries.

De fato, utilizar o modelo ADL em dados de monitoramento de barragens é coerente, pois, a relação entre as variáveis ambientais e a resposta da barragem não é instantânea. Por exemplo, a inércia térmica cria um atraso na resposta entre a variação de temperatura e as leituras dos instrumentos. Assim como ressalta ICOLD¹ (1989 apud FUSARO, 2007) que existe um *time-lag* entre um fenômeno físico, como variação do nível de água do reservatório, por exemplo, e a resposta dada pelo instrumento.

A metodologia proposta é inovadora quando aplicada a dados de monitoramento de barragens e julga-se extremamente relevante porque na literatura, muitas vezes, os modelos estatísticos nessa área ignoram a presença da multicolinearidade e a autocorrelação das variáveis.

Espera-se, com o modelo válido, contribuir com os técnicos e engenheiros na tomada de decisão no que diz respeito ao monitoramento do bloco estudado, pois uma vez que se constroem intervalos de confiança para os deslocamentos, pode-se avaliar as novas leituras da série quanto a uma possível variabilidade anormal e, assim, iniciar um processo investigativo. A detecção de uma possível anormalidade, seja na estrutura ou em algum instrumento ou ainda, alguma alteração no ambiente, se previamente identificada, medidas corretivas são tomadas a tempo de se evitar danos maiores.

Vale ainda ressaltar que, no caso de barragens, não é possível utilizar limites de controle estatísticos obtidos a partir de um universo de barragens construídas, visto

¹ ICOLD (1989). Monitoring of Dams and their Foundations, Bulletin 68, 375p.

que cada unidade tem comportamento singular e que reflete as situações específicas do projeto e da construção, além de materiais empregados, condições das fundações, aspectos ambientais, entre diversos outros fatores (KUPERMAN, *et al.*, 2003).

A ocorrência de dados da instrumentação em desacordo com os valores previstos por um modelo não implica necessariamente em uma situação-problema. Por outro lado, mesmo quando os dados estão entre as faixas admissíveis dos instrumentos, não implicam em ausência de problemas (FUSARO, 2007). Ou seja, a experiência dos engenheiros e técnicos em segurança de barragens sempre será essencial quanto à segurança da estrutura, seja nas ações de inspeções visuais periódicas ou nas análises dos dados da instrumentação.

1.4 ESTRUTURA DO TRABALHO

Este trabalho está organizado em cinco capítulos, sendo o primeiro capítulo destinado a esta introdução.

O segundo capítulo traz uma revisão de literatura, contemplando informações referentes à instrumentação e monitoramento de barragens de concreto, descrevendo os modelos de previsão e testes estatísticos que constituíram a base teórica da tese, além da apresentação do estado da arte no que diz respeito à aplicação de modelos e técnicas estatísticas no contexto de monitoramento de barragens de concreto.

O terceiro capítulo, de materiais e métodos, apresenta a barragem de Itaipu e a descrição dos dados utilizados na modelagem, bem como a descrição das fases realizadas na tese para alcançar os objetivos.

O quarto capítulo é dedicado à análise dos resultados, onde são realizadas a descrição e discussão dos resultados obtidos na realização das fases descritas no terceiro capítulo.

A conclusão e as principais contribuições deste estudo, além das sugestões para trabalhos futuros, são apresentadas no quinto e último capítulo.

No final do texto encontram-se os Apêndices A, B, C, D e E que tratam sobre *scripts*, tabelas, descrição de modelos utilizados para comparação e comandos utilizados na modelagem e previsão.

2 REVISÃO DA LITERATURA

Neste capítulo são abordados os assuntos que constituíram o referencial teórico necessário para desenvolvimento da metodologia desta tese.

2.1 INSTRUMENTAÇÃO E MONITORAMENTO DE BARRAGENS

A segurança de uma barragem depende de um programa de vigilância cuidadosamente planejado e implementado. Este programa de vigilância consiste de observação visual da estrutura realizada periodicamente e instrumentação devidamente instalada de modo a mensurar grandezas de interesse (AHMADI-NEDUSHAN, 2002).

A instrumentação consiste em equipamentos de sistemas elétricos e mecânicos utilizados para medir a pressão, fluxo, deslocamento, tensão, deformação e temperatura e o monitoramento consiste na coleta, redução, apresentação e avaliação destes dados de instrumentação. Portanto, instrumentação e monitoramento são ferramentas para avaliar continuamente a segurança de uma barragem (FERC, 2008).

Segundo Silveira (2003), avaliar o relacionamento entre as medidas obtidas pela instrumentação pode auxiliar na determinação de ações que objetivam remediar efeitos indesejados por meio da atenuação de suas causas.

A instrumentação normalmente fornece dados para avaliar o comportamento durante a construção, no primeiro enchimento e na fase operacional. Durante o período operacional, o monitoramento pode detectar variações nas condições de segurança, como resultado de processos de envelhecimento e alterações ambientais (SARÉ *et al.*, 2006).


Há diversos tipos de barragens caracterizadas de acordo com a finalidade, forma e material empregado na construção. Restringindo-se às barragens de concreto, objeto de estudo desta tese, na Figura 1 apresenta-se uma relação entre os tipos de instrumentos usualmente empregados e os principais tipos de deterioração que podem ser detectados pelos mesmos. Vale ressaltar que a Figura 1 apresenta as inspeções visuais como imprescindíveis na percepção da maioria dos tipos de deterioração.

O pêndulo direto, por exemplo, instalado na estrutura de concreto, está relacionado aos seguintes tipos de deterioração: escorregamento (descontinuidades na fundação), recalque diferencial, subsidência do terreno e reatividade álcali-agregado (Figura 1). Segundo Silveira (2003), este instrumento é utilizado na medição dos deslocamentos horizontais da crista da barragem, que são afetados pelas seguintes grandezas físicas:

- Deflexão da estrutura de concreto;
- Rotação da base da estrutura, devido à deformabilidade da fundação;
- Influências térmicas ambientais.

Já o pêndulo invertido, instalado na fundação, está relacionado ao escorregamento (Figura 1). Este instrumento é utilizado na medição de deslocamentos cisalhantes da base da barragem (deslocamentos horizontais), que segundo Silveira (2003), refletem diretamente as condições de estabilidade da barragem, em termos de escorregamento.

FIGURA 1 - INSTRUMENTAÇÃO E TIPO DE DETERIORAÇÃO DETECTADA



FONTE: Silveira (2003).

As leituras dos deslocamentos horizontais mensurados pelos pêndulos são realizadas pelos coordenômetros óticos ou telecoordenômetros, segundo as direções montante-jusante (x) e margem direita-esquerda (y) (MATOS, 2002).

Os pêndulos diretos são instalados fixos à crista da barragem, indo até o contato concreto-rocha, assim ao nível da crista as componentes x e y do

deslocamento podem ser calculadas. Estes deslocamentos são relativos, pois são deslocamentos horizontais de vários pontos da estrutura em relação a outros pontos da mesma estrutura.

Ao nível da fundação, as componentes x e y dos deslocamentos são calculadas pelos pêndulos invertidos. Estes são instalados, fixos à fundação, a uma profundidade considerada sem influência de cargas, indo até o contato concreto-rocha, determinando os deslocamentos de pontos próximos ao contato concreto-rocha, em relação aos pontos fixos na fundação. Para se determinar os deslocamentos absolutos dos outros pontos da estrutura é necessário fixar a base de menor cota, do pêndulo direto, o mais próximo possível, com a base da leitura do pêndulo invertido (Figura 2).

A instalação de instrumentos ou acumulação de dados do instrumento por si só, não garantem a segurança da barragem. Os instrumentos devem ser cuidadosamente selecionados, localizados e instalados. E além disso, os dados também devem ser criteriosamente avaliados em tempo hábil (FERC, 2008).

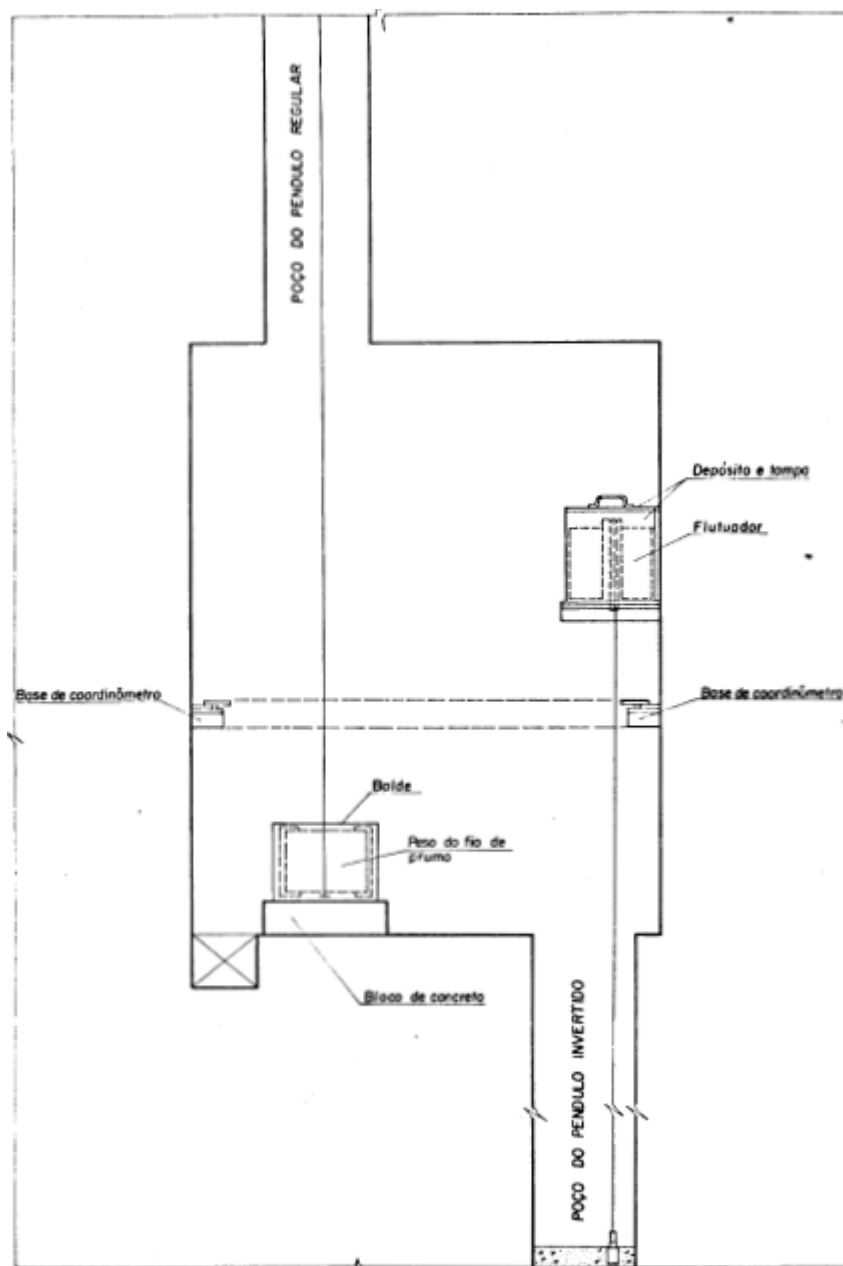
Fusaro (2007) defende que a possível deficiência dos atuais programas de avaliação do comportamento de barragens é o fato de que os dados permanecem sem interpretação até que sua análise se torne tardia ou obsoleta pela aquisição de novas leituras.

Para Matos (2002) o processo de segurança de barragens se efetiva através de monitoramento continuado, que consiste na obtenção de dados fornecidos pelos instrumentos instalados, das relações e análises estatísticas dos mesmos.

Assim, ainda que uma barragem de concreto esteja com instrumentação requerida e devidamente instalada, a análise e interpretação dos dados obtidos pela instrumentação é necessária e essencial para um monitoramento efetivo da estrutura, corroborando com a segurança da mesma.

Segue então, uma breve descrição dos modelos estatísticos que podem ser utilizados para análise e interpretação dos dados da instrumentação de barragens.

FIGURA 2 - ESQUEMA DE INSTALAÇÃO DOS PÊNDULOS DIRETO E INVERTIDO



FONTE: VASCONCELOS (1978).

2.2 MODELOS ESTATÍSTICOS NO MONITORAMENTO DE BARRAGENS

Modelos estatísticos têm sido utilizados para analisar e interpretar os dados da instrumentação de barragens. Geralmente são baseados em correlações existentes entre fatores como o nível de água do reservatório, a temperatura ambiente, entre outros e os efeitos causados na barragem, como tensões, deformações e deslocamentos.

Os modelos de regressão linear múltipla para dados de monitoramento de barragem são baseados em dois pressupostos. O primeiro é que os efeitos são analisados em um período em que a configuração da barragem continua a mesma e o segundo é que a resposta da barragem é separada em efeitos reversíveis (devido à variação do nível do reservatório e temperatura do ar) e irreversíveis (devido a degradação ou fluência). A resposta de um instrumento (por exemplo, deslocamento), no instante i , pode ser modelada da seguinte forma (AHMADI-NEDUSHAN, 2002)

$$D_i(t) = F_i(t) + G_i(H) + H_i(T) + \varepsilon_i \quad (1)$$

onde:

- $F(t)$ é a função que descreve o efeito irreversível;
- $G(H)$ é a função do nível do reservatório (carga hidrostática);
- $H(T)$ é a função da temperatura e
- ε é o erro.

Na literatura são encontradas várias funções propostas para modelar as diferentes componentes de resposta, principalmente quando se trata de modelar $F(t)$ e $H(t)$. Algumas destas versões serão comentadas aqui.

No período operacional normal de uma barragem de concreto, o efeito térmico é diretamente relacionado às variações de temperatura e a inércia térmica cria um atraso na resposta entre a variação de temperatura e as leituras dos instrumentos. Existem duas abordagens para descrever este efeito térmico: a do modelo HST e a dos modelos que consideram a temperatura do concreto.

O modelo HST foi proposto inicialmente em 1958 por Ferry, Will e Beaujoint (CHOUINARD e ROY, 2006), algumas versões são encontradas na literatura para melhor ajuste do modelo ao estudo de caso; cita-se Ahmadi-Nedushan (2002), De Sortis e Paoliani (2007), Xi *et al.* (2011), Mata (2011) e Li, Wang e Liu (2013).

No modelo HST, o efeito do nível do reservatório é modelado por um polinômio de quarto grau, o efeito da temperatura por uma soma de funções trigonométricas e os efeitos irreversíveis por uma função polinomial do tempo (AHMADI-NEDUSHAN, 2002) da seguinte forma:

$$D(t) = H(z) + S(\theta) + T(t) \quad (2)$$

onde:

$$\bullet \quad H(z) = a_1 + a_2 z + a_3 z^2 + a_4 z^3 + a_5 z^4 \quad (3)$$

$$\bullet \quad S(\theta) = a_6 \sin(\theta) + a_7 \cos(\theta) + a_8 \sin(\theta) \cos(\theta) + a_9 \sin^2(\theta) \quad (4)$$

$$\bullet \quad T(t) = c_1 t + c_2 t^2 + c_3 t^3 \quad (5)$$

O fator $D(t)$ é a variável resposta (por exemplo, deslocamentos), $H(z)$, $S(\theta)$, $T(t)$ são respectivamente a função do nível do reservatório, a função da temperatura e o efeito irreversível, sendo t o número de dias desde que se iniciou a análise. As variáveis z e θ são definidas como $z = \frac{h - h_{\min}}{h_{\max} - h_{\min}}$, h nível do reservatório e

$$\theta = \frac{2\pi j}{365}, \quad j = 1, \dots, 365.$$

YU *et al.* (2010) utilizam o HST na mesma formulação apresentada acima, no entanto, muitos autores utilizam variações do modelo, algumas das quais são destacadas aqui.

De Sortis e Paoliani (2007) utilizam esse modelo supondo a função do efeito irreversível como uma linha de tendência, assim o modelo é dado por, (2), (3) e (4), substituindo a equação (5) por

$$T(t) = c_0 + c_1 t \quad (6)$$

Em Xi *et al.* (2011), o modelo é dado por (2), (3) e (4), substituindo a equação (5) por

$$T(t) = c_1 \theta + c_2 \ln(\theta) \quad (7)$$

Mata (2011) utiliza para a modelagem do efeito irreversível a função

$$T(t) = c_1 t + c_2 e^{-t} \quad (8)$$

Li, Wang e Liu (2013) utilizam

$$T(t) = c_1\theta + c_2\ln(\theta + 1) \quad (9)$$

para modelagem do efeito irreversível, onde θ é o número de dias desde que começou a análise e cada dia passado representa um acréscimo de 0,01. Ainda, Simon *et al.* (2013) utilizam a função

$$T(t) = c_0 e^{-t} + c_1 t + c_2 t^2 + c_3 t^3 + c_4 t^4 \quad (10)$$

Os coeficientes desconhecidos a_k e c_l são calculados por uma minimização da diferença entre as medidas reais e as medidas obtidas pelo modelo em (2), usando o método dos mínimos quadrados ordinário. Note que o modelo HST é construído por meio de funções não lineares, mas como os valores das variáveis de entrada são conhecidos pelo pesquisador (tempo e nível do reservatório) o modelo se torna linear ao passo que estas variáveis são substituídas nas funções.

Seguem algumas considerações a respeito do modelo HST e suas variações. Estes modelos fazem uso de hipóteses fortes sobre a resposta da barragem, que geralmente não são válidas, como considerar os efeitos reversíveis e irreversíveis como independentes (SALAZAR *et al.*, 2015). É bem conhecida a existência de certa colinearidade, por exemplo, o nível do reservatório afeta a resposta térmica da barragem (TATIN *et al.*, 2015). A colinearidade, ou multicolinearidade, em modelos de regressão, reduz o poder preditivo de qualquer variável independente pela extensão com a qual está associada com as outras variáveis independentes (HAIR *et al.*, 2009). Assim, a precisão da previsão do modelo fica comprometida.

Outra limitação da forma original do modelo HST é que a temperatura do ar não é considerada, o que reduz a precisão da previsão para um ano de temperaturas extremas, por exemplo (SALAZAR *et al.*, 2015).

Uma alternativa comum na literatura é substituir a função periódica da temperatura pela temperatura no concreto da barragem. Este modelo denomina-se *hydrostatic-temperature-time* (HTT). Segundo Léger e Leclerc (2007), quando há variação sazonal do nível do reservatório em fase com a variação sazonal de temperatura, as variáveis de $H(z)$ e $S(\theta)$ na equação (2) são correlacionadas,

ficando difícil separar os efeitos hidrodinâmicos e sazonais. Os autores utilizam dados dos termômetros embutidos na barragem, substituindo a função da temperatura $S(\theta)$ de HST (equação 4) por

$$S(T) = \sum_{i=1}^k b_i T_i \quad (11)$$

onde b_i são os coeficientes e T_i são os dados dos termômetros $1, 2, \dots, k$. Assim,

$$D(t) = H(z) + S(T) + T(t) \quad (12)$$

Uma dificuldade desta abordagem é quais termômetros utilizar entre os disponíveis. Alguns autores consideram todos (SALAZAR *et al.*, 2015). Mata, de Castro e da Costa (2014) representam o efeito térmico com as componentes principais dos termômetros instalados no concreto e compara com os resultados dos modelos HST e HTT, obtendo melhores resultados com o modelo proposto que se denomina $HT_{PCA}T$.

Li, Wang e Liu (2013) colocam que modelos de regressão linear múltipla são os mais utilizados em dados de monitoramento de barragens e só podem ser utilizados em séries temporais estacionárias. No entanto, o autor afirma que as séries não são estacionárias em sua maioria. Uma regressão espúria pode acontecer ao utilizar um modelo de regressão linear múltipla sem testar a estacionariedade das séries, diminuindo assim a precisão da previsão. Assim, o autor apresenta um modelo de correção de erros, após verificação de não estacionariedade e presença de séries temporais cointegradas. O modelo de correção de erros exibiu melhor ajuste e precisão de previsão quando comparado ao modelo HTT.

Outro aspecto relevante é que a barragem de concreto responde com algum atraso (*delay*) às solicitações externas, por exemplo, deslocamentos da estrutura de uma barragem em arco não dependem exclusivamente da variação instantânea do nível do reservatório, mas também de seus valores passados (LOMBARDI, AMBERG e DARBRE, 2008). Outro exemplo é a influência da temperatura do ar no corpo da barragem de concreto entre as temporadas de inverno e verão.

Segundo Salazar *et al.* (2015) várias abordagens são propostas para considerar estes atrasos na resposta da barragem. A maioria destas abordagens são construídas com a determinação de médias móveis e gradientes.

Demirkaya e Balcilar² (2012 apud SALAZAR *et al.* 2015) realizaram uma análise de sensibilidade para selecionar o número de valores passados (defasagens) que incluirão em um modelo de regressão linear múltipla e em um modelo de redes neurais. Constataram que os resultados mais precisos foram obtidos com um modelo de regressão linear múltipla considerando os dados de 30 dias anteriores. A crítica a este estudo é na hipótese que a barragem respondeu com o mesmo atraso à variação do nível do reservatório, à temperatura do ar e à temperatura no corpo da barragem.

Lombardi, Amberg e Darbre (2008) calcularam a resposta térmica da barragem sob a ação da variação da temperatura do ar. Utilizando uma aproximação numérica, chegaram à seguinte expressão:

$$\hat{Y}(t) = \alpha Y(t - \Delta t) + \left(1 + \frac{\alpha}{\beta} - \frac{1}{\beta}\right) X(t) + \left(\frac{1}{\beta} - \frac{\alpha}{\beta} - \alpha\right) X(t - \Delta t) \quad (13)$$

onde os parâmetros α , β e Δt são definidos por: $\alpha = e^{\frac{-\Delta t}{t_0}}$, $\beta = \frac{\Delta t}{t_0}$ e Δt é o intervalo de medição. Na verdade, esse é um modelo autorregressivo com variável exógena (ARX). São modelos que podem ser considerados como uma extensão dos modelos autorregressivos (AR) quando uma nova série temporal X é usada para descrever a variável Y .

Em geral, o uso do valor real anterior (defasado) para ajustar o modelo proporciona uma melhor precisão da previsão, mas tal modelo não seria capaz de detectar anomalias graduais, pois seria aprender o comportamento anormal e tratá-lo como comum. Uma alternativa seria ajustar o modelo aos dados de um determinado período de tempo e fazer previsões a longo prazo prevendo uma saída em $t+1$ e utilizá-la na previsão de $t+2$ (não utilizar a observação real de $t+1$). Neste procedimento ocorre a propagação do erro, no entanto, é apropriado para revelar anomalias graduais. Apesar de vários autores construírem modelos preditivos com base em

² Demirkaya S.; Balcilar M. The contribution of soft computing techniques for the interpretation of dam deformation. In: Proceedings of the FIG working week. Rome, Italy, 2012.

valores de saída defasados, a maioria deles não menciona qual a abordagem de previsão utilizada (SALAZAR *et al.*, 2015).

Nos últimos anos, muitos artigos sobre modelos de previsão em dados de monitoramento de barragens surgiram com aplicação em dados de Itaipu, sendo alguns deles comentados a seguir.

Rodrigues *et al.*, (2015) propõem uma modelagem híbrida para previsão de séries temporais usando os modelos ARIMA, decomposição Wavelet, a regressão de vetores suporte (SVR) e a combinação de previsões. Os dados utilizados são de uma base de alongâmetro que mede os deslocamentos diferenciais entre blocos do trecho I da barragem. Os resultados apresentaram que o modelo com combinações de previsões teve menores erros. Neste trabalho não foram construídos intervalos de confiança.

Previsões para a série de vazões mensais no posto 266 da barragem de Itaipu foram obtidas utilizando métodos de Box e Jenkins, Redes Neurais Artificiais (RNA) e Wavelet_RNA. As previsões obtidas com esses métodos foram comparadas e na amostra de teste, o erro médio percentual absoluto (MAPE) obtido com o método formado por uma combinação Wavelet_RNA e encolhimento wavelet foi de 1,30%, muito inferior aos erros com os métodos individuais de Box-Jenkins e RNA (TEIXEIRA, SIQUEIRA e TEIXEIRA JÚNIOR, 2015).

Corrêa (2015) propôs o método WARIMAX-GARCH Neural para previsão de séries temporais diárias de deslocamentos horizontais de blocos da barragem de Itaipu. Comparou os resultados contra o modelo ARIMA-GARCH e mostrou que o seu método produz performance de previsão significativamente melhor e de uma forma operacionalmente mais simples. Corrêa (2015) trabalha com 5 sensores dos pêndulos diretos nos blocos chave da Barragem Principal, mas não considera o sensor F19y, variável nesta tese denominada *pd_y*. Sobre o pré-processamento dos dados, a ideia utilizada foi considerar os valores aferidos diariamente no mesmo horário, entre os dias 28/10/2005 e 24/10/2012, de forma automatizada. Trabalha-se com a série completa, mas não se menciona sobre dados ausentes e *outliers*.

Pereira (2016) apresenta duas metodologias híbridas, compostas por ARIMA, RNA-RBF (Redes Neurais Artificiais de Funções de Bases Radiais) e da Decomposição Wavelet. A aplicação das metodologias em três séries conhecidas na literatura identificou que a metodologia proposta obteve melhor desempenho. Assim, a metodologia proposta foi aplicada à série temporal do piezômetro PS-F-72, com

periodicidade quinzenal (leituras manuais), instalado na fundação do bloco F19/20 da Barragem de Itaipu. O erro MSE foi de 0,086 na amostra de teste, menor em relação aos modelos ARIMA e Rede Neural de Função de Bases Radiais.

Esses trabalhos têm em comum, além de serem aplicados a dados de instrumentação de Itaipu, a metodologia híbrida que associa modelos estatísticos a técnicas de redes neurais.

2.3 MODELOS AUTOREGRESSIVOS DE DEFASAGENS DISTRIBUÍDAS

O modelo autoregressivo de defasagens distribuídas (ADL) engloba uma classe de modelos dinâmicos em que os regressores incluem valores defasados da variável dependente e valores correntes e defasados das variáveis independentes. Segue um modelo ADL(r,s) onde por simplicidade considera-se apenas uma variável independente, x_t ,

$$y_t = \mu + \sum_{i=1}^r \alpha_i y_{t-i} + \sum_{i=0}^s \beta_i x_{t-i} + \varepsilon_t \quad (14)$$

Na equação (14) μ representa o termo independente, os índices r e s representam, respectivamente, o número máximo de defasagem para a variável dependente, y_t , e independente, x_t . Os erros ε_t devem ser independentes e identicamente distribuídos.

Na especificação do modelo, dois aspectos são fundamentais: a determinação das ordens de defasagem (r e s) e a estimação dos coeficientes. Quanto à determinação da ordem de defasagem, algumas alternativas incluem a escolha do modelo que maximiza o coeficiente de determinação ou minimiza a estimativa da variância dos erros, e, os critérios de informação como, por exemplo, o de Akaike (AIC) e da estatística Bayesiana de Schwarz (BIC). Quanto à estimação, transformações lineares são aplicadas no modelo ADL de forma a atenuar os problemas de multicolinearidade e recorre-se ao método de estimação por mínimos quadrados ordinários, que além de ser consistente é invariante a transformações lineares (ARONE, 2014).

2.3.1 Modelo de Correção de Erros (ECM)

O modelo de correção de erros (*Error Correction Model* - ECM) é uma parametrização de um modelo ADL que oferece vantagens, como por exemplo, atenuar problemas de multicolinearidade entre as variáveis preditoras (ARONE, 2014).

Seja o modelo ADL(r,s) dado por

$$y_t = \mu + \sum_{i=1}^r \alpha_i y_{t-i} + \sum_{i=0}^s \beta_i x_{t-i} + \varepsilon_t \quad (15)$$

usando o operador de defasagem e deduções polinomiais, tem-se

$$A(L)y_t = \mu + B(L)x_t + \varepsilon_t \quad (16)$$

onde $A(L) = 1 - \sum_{i=1}^r \alpha_i L^i$ e $B(L) = \sum_{i=0}^s \beta_i L^i$.

Com manipulação algébrica prova-se que

$$A(L) = A(1)L + (1-L) \left(1 - \sum_{i=1}^{r-1} \delta_i L^i \right) \quad (17)$$

onde $\delta_i = -\sum_{j=i+1}^p \alpha_j$, $i = 1, \dots, p-1$ e $\delta_0 = 0$ e

$$B(L) = B(1)L + (1-L) \left(\sum_{i=0}^{s-1} \gamma_i L^i \right) \quad (18)$$

onde $\gamma_i = -\sum_{j=i+1}^p \beta_j$, $i = 1, \dots, p-1$ e $\gamma_0 = \beta_0$. Substituindo (17) e (18) em (16) segue que

$$\left[A(1)L + (1-L) \left(1 - \sum_{i=1}^{r-1} \delta_i L^i \right) \right] y_t = \mu + \left[B(1)L + (1-L) \left(\sum_{i=0}^{s-1} \gamma_i L^i \right) \right] x_t + \varepsilon_t \quad (19)$$

Seguem algumas expressões equivalentes a (19) onde foram se efetuando os produtos e aplicando o operador defasagem nas variáveis.

$$\begin{aligned}
A(1)Ly_t + \left(1 - \sum_{i=1}^{r-1} \delta_i L^i\right)(y_t - Ly_t) &= \mu + B(1)Lx_t + \left(\sum_{i=0}^{s-1} \gamma_i L^i\right)(x_t - Lx_t) + \varepsilon_t \Leftrightarrow \\
A(1)y_{t-1} + \left(1 - \sum_{i=1}^{r-1} \delta_i L^i\right)\Delta y_t &= \mu + B(1)x_{t-1} + \left(\sum_{i=0}^{s-1} \gamma_i L^i\right)\Delta x_t + \varepsilon_t \Leftrightarrow \\
\Delta y_t &= \mu - A(1)y_{t-1} + B(1)x_{t-1} + \sum_{i=1}^{r-1} \delta_i L^i \Delta y_t + \sum_{i=0}^{s-1} \gamma_i L^i \Delta x_t + \varepsilon_t \Leftrightarrow \\
\Delta y_t &= \mu - A(1)y_{t-1} + B(1)x_{t-1} + \sum_{i=1}^{r-1} \delta_i \Delta y_{t-i} + \sum_{i=0}^{s-1} \gamma_i \Delta x_{t-i} + \varepsilon_t
\end{aligned}$$

Igualando $-A(1) = \phi$ e colocando em evidência, obtém-se a seguinte representação para o modelo de correção de erros

$$\Delta y_t = \mu + \phi \left[y_{t-1} - \frac{B(1)}{A(1)} x_{t-1} \right] + \sum_{i=1}^{r-1} \delta_i \Delta y_{t-i} + \sum_{i=0}^{s-1} \gamma_i \Delta x_{t-i} + \varepsilon_t \quad (20)$$

A reparametrização da equação (15) para a equação (20) oferece vantagens na estimação e nada mais é do que transformações lineares aplicadas ao modelo ADL, sem a imposição de qualquer restrição. As mesmas estimativas do estimador por mínimos quadrados ordinário com as variáveis originais são fornecidas, pois o mesmo é invariante às transformações lineares (LOPES, 1999). O modelo em (20) é conhecido como modelo ADL na forma de Bårdsen.

2.3.2 A Abordagem *Bounds Testing*

A abordagem proposta por Pesaran, Shin e Smith (2001) parte da reformulação do modelo ADL para m variáveis independentes X_1, \dots, X_m

$$Y_t = \mu + \sigma t + \sum_{i=1}^p \alpha_i Y_{t-i} + \left(\sum_{i=0}^{q_1} \beta_{1i} X_{1,t-i} + \dots + \sum_{i=0}^{q_m} \beta_{mi} X_{m,t-i} \right) + \varepsilon_t \quad (21)$$

O procedimento é adotado por várias razões. Em primeiro lugar, o procedimento denominado *Bounds Testing* é mais simples do que outras técnicas, tais como a cointegração multivariada de Johansen e Juselius. Em segundo lugar, o teste é aplicável independentemente se os regressores no modelo são puramente estacionários, $I(0)$ ou puramente integrados de ordem 1, $I(1)$. No entanto, na presença

de alguma série integrada de ordem 2, o procedimento falha. Em terceiro lugar, o teste é relativamente mais eficiente em tamanhos de amostra de dados de pequena dimensão (FRIMPONG e OTENG-ABAYIE, 2006).

Nesta aplicação, embora os regressores sejam $I(0)$, as séries de dados das variáveis dependentes são $I(1)$, esta mistura de séries $I(0)$ e $I(1)$ favorece a utilização da abordagem do *Bounds Testing*.

Primeiramente, define-se o número de defasagens no modelo $ADL(p, q_1, \dots, q_m)$ da equação (21). Feito isto, estima-se por mínimos quadrados ordinários, a equação do modelo de correção de erro irrestrito, também conhecido como ECM irrestrito. O ECM irrestrito é um tipo particular de modelo ADL (ADL na forma de Bårdsen), dado por

$$\Delta Y_t = \mu + \sigma t + \sum_{i=1}^{p-1} \alpha_i \Delta Y_{t-i} + \left(\sum_{k=0}^{q_1-1} \beta_{1k} \Delta X_{1,t-k} + \dots + \sum_{k=0}^{q_m-1} \beta_{mk} \Delta X_{m,t-k} \right) + \theta_0 Y_{t-1} + \sum_{l=1}^m \theta_l X_{l,t-1} + \varepsilon_t \quad (22)$$

O objetivo é testar se existe uma relação de longo prazo entre as variáveis. Isso é realizado por meio de um teste F para a significância conjunta dos coeficientes das séries das variáveis defasadas, ou seja, $H_0 : \theta_0 = \theta_1 = \dots = \theta_m = 0$ contra a alternativa de que ao menos um dos θ_l é não nulo. Dois valores de fronteira são fornecidos para testar a cointegração quando as variáveis independentes são $I(0)$ ou $I(1)$: um valor inferior assumindo que os regressores são $I(0)$ e um limite superior assumindo que os regressores são $I(1)$. Se a estatística F é superior ao valor crítico superior, a hipótese nula de ausência de relação de longo prazo pode ser rejeitada, independentemente das ordens de integração para as séries temporais, ou seja, existe cointegração. Por outro lado, se a estatística do teste for inferior ao valor crítico inferior, a hipótese nula não pode ser rejeitada e não há cointegração. Finalmente, se a estatística cai entre os valores críticos superiores e inferiores, o resultado é inconclusivo (FRIMPONG e OTENG-ABAYIE, 2006). Os dois conjuntos dos valores críticos foram reportados em Pesaran, Shin e Smith (2001) para modelos como em (22), com inclusão do termo constante e tendência ($\mu + \sigma t$), com inclusão do termo constante (μ), e sem a inclusão do termo constante e tendência.

No próximo passo, uma vez que exista a cointegração, são obtidos os parâmetros do modelo dinâmico de curto prazo por meio da estimação de um modelo de correção de erros associado com as estimativas de longo prazo; este é denominado ECM restrito ou condicional. As defasagens do modelo ECM restrito são associadas à relação do modelo ADL acima (equação 22). O ECM restrito é dado por

$$\Delta Y_t = \sum_{i=1}^{p-1} \lambda_i \Delta Y_{t-i} + \left(\sum_{k=0}^{q_1-1} \delta_{1k} \Delta X_{1,t-k} + \dots + \sum_{k=0}^{q_m-1} \delta_{mk} \Delta X_{m,t-k} \right) + \gamma t + \rho + \varphi Z_{t-1} + \varepsilon_t \quad (23)$$

onde $Z_{t-1} = Y_{t-1} - a_0 - a_1 X_{1,t-1} - a_2 X_{2,t-1} - \dots - a_m X_{m,t-1}$ e os coeficientes $a_i, i = 1, \dots, m$ são as estimativas por mínimos quadrados ordinários dos coeficientes $\alpha_i, i = 1, \dots, m$ na equação

$$Y_t = \alpha_0 + \alpha_1 X_{1,t} + \alpha_2 X_{2,t} + \dots + \alpha_m X_{m,t} + v_t \quad (24)$$

Observe que o modelo ECM restrito (equação 23) difere do modelo ECM irrestrito (equação 22) apenas no termo de correção do erro Z_t . O ECM restrito restringe seus coeficientes à relação de longo prazo em (24). Em (23), λ, δ, γ e ρ são os coeficientes dinâmicos do modelo de curto prazo que converge ao equilíbrio, onde φ é a velocidade do ajustamento.

2.4 TESTES DE DIAGNÓSTICO DO MODELO

Geralmente uma bateria de testes é aplicada ao modelo para verificar se o mesmo produz resultados confiáveis ou não. Gerrard e Godfrey (1998) argumentam que a aplicação dos testes de diagnóstico do modelo deve ser realizada no modelo ECM, pois alguns testes são sensíveis à presença de variáveis integradas.

Utilizam-se nesta aplicação alguns deles como o teste RESET (*Regression Specification Error Test*) para detectar a forma funcional incorreta do modelo e para a análise dos resíduos, o teste de autocorrelação de Breusch-Godfrey. A descrição destes testes segue abaixo.

2.4.1 Teste RESET (*Regression Specification Error Test*)

Um modelo de regressão múltipla sofre de forma funcional incorreta quando não explica a relação entre a variável dependente e as variáveis independentes corretamente. Alguns testes foram propostos para detectar a forma funcional incorreta, como o teste RESET (*Regression Specification Error Test*) de Ramsey.

Seja o modelo original

$$y = \alpha_1 x_1 + \dots + \alpha_k x_k + \varepsilon \quad (25)$$

onde o termo estocástico tem média condicional zero ($E(\varepsilon | x_1, \dots, x_k) = 0$), então não há funções significativas, não lineares das variáveis independentes, que sejam adicionadas ao modelo. Esta equação (25) varia de acordo com o modelo a ser testado. O teste RESET acrescenta polinômios à equação (25) após a estimação dos parâmetros por mínimos quadrados ordinários para detectar a forma funcional incorreta.

Ao implementar o teste RESET decide-se quais funções dos valores ajustados serão incluídas na regressão. Não há resposta certa para esta pergunta, mas os termos quadrados e cubos se mostraram suficientes na maioria das aplicações.

Seja a equação expandida dada por

$$y = \alpha_1 x_1 + \dots + \alpha_k x_k + \beta_1 \hat{y}^2 + \beta_2 \hat{y}^3 + \varepsilon \quad (26)$$

A hipótese nula é que o modelo em (25) está especificado corretamente. Assim, RESET é a estatística F para testar $H_0 : \beta_1 = 0, \beta_2 = 0$ no modelo expandido (26). Uma estatística significativa F sugere algum tipo de problema na especificação do modelo. A distribuição da estatística F é de aproximadamente $F_{(n_t, n-k-1-n_t)}$ em grandes amostras sob a hipótese nula, onde n_t é o número de termos ajustados.

É importante notar que não há nenhum interesse nos parâmetros estimados em (26), a equação é usada exclusivamente para testar se (25) deixou de considerar não-linearidades importantes. Geralmente, utilizar \hat{y}^2 e \hat{y}^3 , ou seja, $n_t = 2$ ou $n_t = 3$ já é considerado suficiente (WOOLDRIDGE, 2006).

2.4.2 Teste de autocorrelação Breusch-Godfrey

Breusch e Godfrey desenvolveram um teste para verificar a presença de autocorrelação nos erros de um modelo de regressão por mínimos quadrados ordinários. O teste de Breusch-Godfrey é adotado por ser aplicável a modelos com defasagens de variáveis dependentes e por considerar altas ordens de autocorrelação. Consiste em modelar por um processo $AR(q)$ os resíduos do modelo por mínimos quadrados ordinários e derivar um teste estatístico. A hipótese nula é de que não existe uma correlação de qualquer ordem até q (ASTERIOU e HALL, 2011).

Seja o modelo dado por

$$y_t = \alpha_0 + \alpha_1 x_{1t} + \alpha_2 x_{2t} + \dots + \alpha_k x_{kt} + \varepsilon_t \quad (27)$$

onde

$$\varepsilon_t = \rho_1 \varepsilon_{t-1} + \rho_2 \varepsilon_{t-2} + \dots + \rho_q \varepsilon_{t-q} + \eta_t \quad (28)$$

Assim, o modelo fica

$$y_t = \alpha_0 + \alpha_1 x_{1t} + \alpha_2 x_{2t} + \dots + \alpha_k x_{kt} + \rho_1 \varepsilon_{t-1} + \rho_2 \varepsilon_{t-2} + \dots + \rho_q \varepsilon_{t-q} + \eta_t \quad (29)$$

e a hipótese nula é dada por $H_0: \rho_1 = \rho_2 = \dots = \rho_q = 0$, ou seja, ausência de autocorrelação contra H_1 : ao menos um dos ρ_j não nulo, indicando a presença de autocorrelação.

A estatística LM (*Lagrange Multiplier*) é calculada por $(n-q)R^2$ da regressão em (29) onde R^2 é o usual coeficiente de determinação. Se a estatística LM é maior que χ_q^2 o valor crítico para um dado nível de significância, então, a hipótese nula é rejeitada e conclui-se que a autocorrelação existe (ASTERIOU e HALL, 2011). O teste é por vezes referido como teste LM para a correlação serial (WOOLDRIDGE, 2006).

2.5 CONSIDERAÇÕES RELEVANTES PARA FINS DE PREVISÃO

Algumas considerações importantes que antecedem a previsão a ser realizada pelo modelo ajustado serão abordadas aqui como: pré-processamento dos dados, conjunto de treinamento e conjunto de teste, medidas de avaliação de erro e tipo de previsão realizada.

Salazar *et al.* (2015) destacam que a grande maioria dos trabalhos existentes que se referem a modelos para predição do comportamento de barragens se esquecem do pré-processamento dos dados. Na revisão dos artigos nesta área, Salazar *et al.* (2015) comentam que os autores geralmente supõem que os dados de monitoramento estão livres de erros de leitura e valores ausentes, enquanto que na prática isso não é verdade.

Nos dados de monitoramento de barragens existem várias causas que podem provocar valores errados de leitura ou ausência dos mesmos como: uma falha no sensor, necessidade de manutenção, troca ou até mesmo desativação do instrumento por já ter cumprido sua vida útil; falha no sistema de aquisição de dados; ou ainda, uma inspeção dos engenheiros ou técnicos que necessitasse interromper o funcionamento do instrumento.

Villwock (2009) encontra alguns instrumentos com leituras ausentes e, para estes, foram realizadas interpolações por séries temporais garantindo, desta forma, que todos os instrumentos tivessem exatamente o mesmo número de leituras. Sua aplicação foi realizada com dados de instrumentação dos extensômetros instalados nos blocos da Barragem Principal de Itaipu. O objetivo maior deste trabalho foi o de hierarquizar estes instrumentos, maximizando a eficácia e eficiência das análises das leituras.

Oro *et al.* (2016) utilizaram modelos ARIMA para realizar as previsões pelo procedimento *forecasting/backforecasting*, que consiste em modelar a série temporal após a ocorrência do dado ausente e anteriormente a ocorrência do dado ausente, fazer a previsão para esse valor em ambas situações e preencher a lacuna com o valor médio das duas previsões. Neste artigo, várias técnicas de análise multivariada são utilizadas para analisar a influência das condições ambientais nos blocos de concreto do tipo contraforte da barragem de Itaipu.

Ambas as aplicações, de Vilwock (2008) e Oro *et al.* (2016), utilizavam dados de instrumentação obtidos pelas observações dos técnicos, de periodicidade quinzenal ou mensal. Quando se trabalha com os dados de instrumentação automatizada, o volume de dados é muito maior (leituras a cada 30 minutos, por exemplo) e, conseqüentemente, o volume de dados ausentes e valores errados aumenta. Se existem muitos períodos que precisam ser preenchidos, o método para preenchimento das séries históricas deve ser revisto de modo a ser mais prático,

principalmente quando o objetivo principal não é a preenchimento de dados e espera-se perder pouco tempo com essa demanda inicial.

É importante destacar que, no que se refere aos dados ausentes, numerosas técnicas estatísticas foram desenvolvidas para preenchimento de dados, no entanto, na revisão dos artigos na área de modelos para previsão do comportamento de barragens, ou nada se menciona sobre essa necessidade, ou não se discute a respeito da escolha do método para preenchimento das falhas.

Outro aspecto relevante é a divisão conveniente dos dados disponíveis em um conjunto de treinamento, utilizado no ajuste dos parâmetros do modelo, e um conjunto de teste (ou validação), exclusivamente utilizado para medir a precisão da previsão. Quando a precisão da previsão de um modelo é medida nos dados de treinamento, ela é superestimada. Assim, um conjunto de teste adequado não deve ser utilizado no ajuste para estimação dos parâmetros.

Os modelos para previsão do comportamento de uma barragem são usados, na prática, para calcular leituras futuras, com base no funcionamento observado, considerado normal, e assim, tirar conclusões sobre o estado de segurança da obra. Portanto, é comum considerar os dados mais recentes para o conjunto de teste. Este é o processo utilizado na grande maioria dos artigos da área (SALAZAR *et al.*, 2015).

É fundamental que o conjunto de treinamento seja de um período em que a configuração da barragem permaneceu a mesma e não sofreu mudanças significativas em seu comportamento (AHMADI-NEDUSHAN, 2002, SALAZAR *et al.*, 2015). A utilização dos dados correspondente ao primeiro período após a construção, por exemplo, para o conjunto de treinamento, poderia aumentar o erro de previsão, pois neste período as deformações lentas da fundação e do concreto ainda não se estabilizaram, nem as influências térmicas ambientais (ITAIPU BINACIONAL, 1997).

Lombardi, Amberg e Darbre (2008) estimam que 12 anos, após a construção da barragem, são necessários para que o banco de dados seja efetivo para a modelagem. Outra situação é qual a quantidade de observações necessárias para se utilizar na modelagem. De Sortis e Paoliani (2007) concluíram em seus estudos que 10 anos foram necessários para a obtenção de resultados estáveis. Chouinard e Roy (2006) afirmaram que, em uma situação em que o nível do reservatório teve pouca variação, ou seja, o efeito térmico é dominante, a cada 5 anos de dados foram suficientes para alcançar alta precisão.

Segundo Salazar *et al.* (2015) os dados para o conjunto de teste devem ser os mais recentes, nos modelos para previsão do comportamento de barragens, mas afirma que, na prática, não há acordo sobre o critério adequado para definir os conjuntos de treinamento e de teste. Assim, a comparação entre os modelos tem confiabilidade limitada.

Quanto às medidas de avaliação de erro, as duas medidas mais comumente utilizadas são baseadas nos erros absolutos ou erros ao quadrado:

- O erro médio absoluto: $MAE = \frac{1}{h} \sum_{t=1}^h |y_t - \hat{y}_t|$.
- Raiz quadrada do erro quadrático médio: $RMSE = \sqrt{\frac{1}{h} \sum_{t=1}^h (y_t - \hat{y}_t)^2}$.

Onde h é o horizonte de previsão, y_t é o valor observado, \hat{y}_t é o valor previsto pelo modelo. A vantagem do RMSE, embora dependente de escala, é que não subestima o impacto de grandes erros, mas pouco frequentes. Uma vez que não envolve a média do erro, dá mais peso para os grandes erros pouco frequentes.

Ao comparar métodos de previsão em um único conjunto de dados, o MAE é popular por ser fácil de entender e calcular. Um problema com o MAE é que a dimensão relativa do erro nem sempre é evidente. Às vezes é difícil distinguir um grande erro de um pequeno erro. Para lidar com este problema, podemos encontrar o erro médio absoluto em termos percentuais.

O percentual do erro tem a vantagem de ser independente de escala, e assim é frequentemente usado para comparar o desempenho de previsões entre diferentes conjuntos de dados. A medida mais comumente utilizada é o:

- Erro percentual absoluto médio: $MAPE = \frac{1}{h} \sum_{t=1}^h \left| \frac{y_t - \hat{y}_t}{y_t} \right| 100$

As medidas baseadas em erros percentuais têm a desvantagem de serem indefinidas se $y_i = 0$ para qualquer i no período de interesse, e ter valores extremos quando qualquer y_i está próximo de zero (HYNDMAN e ATHANASOPOULOS, 2014).

Uma outra crítica é que mesmo com vários autores abordando modelos preditivos para o comportamento de barragens, com base em valores de saída defasados, a maioria deles não menciona qual a abordagem de previsão utilizada (SALAZAR *et al.*, 2015).

A previsão pode ser de duas maneiras distintas: previsões dentro da amostra ou fora da amostra. A primeira considera toda a amostra para estimar o modelo e então analisa o poder preditivo do modelo dentro da própria amostra. A segunda utiliza uma parte da amostra para estimar o modelo e então realiza as previsões para o restante da amostra que não foi utilizado na estimação do modelo. Previsões dentro da amostra consideram toda a informação disponível para estimar o modelo e, portanto, apresentam maior potência. Já as previsões fora da amostra possuem maior aplicação prática por aproximar melhor a restrição de informação que observa-se na vida real.

A previsão fora da amostra é mais indicada para a aplicação apresentada nesta tese e pode ser classificada por: previsão estática e dinâmica. Na previsão estática realiza-se a previsão um passo à frente (*one-step ahead*) para a série da variável dependente. Supondo uma defasagem igual a 1 (um) para a variável dependente e 0 (zero) para a variável independente, sem perda de generalidade, calcula-se cada observação na amostra de previsão por:

$$\hat{y}_{s+k} = \mu + \alpha x_{s+k} + \beta y_{s+k-1}$$

utilizando sempre o valor atual da variável endógena defasada. Na previsão dinâmica realiza-se a previsão vários passos à frente (*multi-step ahead*), iniciando da primeira observação da amostra de previsão. Previsões para observações posteriores à primeira observação da amostra de previsão utilizarão os valores anteriormente previstos de Y e não os observados. Por exemplo, supondo um modelo com 2 (duas) defasagens da variável dependente:

- A primeira observação (\hat{y}_s) vai utilizar os valores atuais das defasagens de y

$$\hat{y}_s = \mu + \alpha_1 x_s + \alpha_2 y_{s-1} + \alpha_3 y_{s-2}$$

- A segunda observação (\hat{y}_{s+1}) usa o valor atual de (y_{s-1}) e o previsto (\hat{y}_s)

$$\hat{y}_{(s+1)} = \mu + \alpha_1 x_{s+1} + \alpha_2 \hat{y}_{(s+1)-1} + \alpha_3 y_{(s+1)-2}$$

E o processo continua para as subseqüentes observações, utilizando os valores previstos anteriormente. A previsão dinâmica exige que os dados para as variáveis independentes (exógenas) estejam disponíveis para cada observação na amostra de previsão, e que os valores para todas as defasagens da variável dependente sejam observados no início da amostra da previsão (NOBLE, 2011).

3 MATERIAIS E MÉTODOS

3.1 USINA HIDRELÉTRICA DE ITAIPU

A Usina Hidrelétrica de Itaipu é uma entidade binacional localizada no Rio Paraná, na fronteira entre Brasil e Paraguai (Figura 3), construída no período de 1975 a 1982 por ambos os países. A Itaipu Binacional é líder mundial em produção de energia limpa e renovável, tendo produzido mais de 2,3 bilhões de MWh desde o início de sua operação, em 1984. Possui 20 unidades geradoras e 14.000 MW de potência instalada, fornece cerca de 15% da energia consumida no Brasil e 75% da consumida no Paraguai. Em 2015, Itaipu produziu um total de 89,2 milhões de MWh (ITAIPU BINACIONAL, 2016).

FIGURA 3 - FOTOGRAFIA AÉREA DA BARRAGEM




FONTE: ITAIPU Binacional (2014)

A barragem possui uma extensão aproximada de 7.700 m e altura máxima de 196 m. Sua estrutura é singular, composta de cinco tipos de represamentos: a barragem de enrocamento formada por núcleo em argila coberto com rochas vindas da escavação do canal de desvio, a barragem de terra composta por argila vinda da escavação da fundação da barragem de enrocamento e das proximidades, a barragem de concreto de gravidade aliviada, gravidade maciça e a de contrafortes.

O reservatório se estende por 1350 km², indo de Foz do Iguaçu e Ciudad del Este, até Guaíra e Salto del Guairá, 150 km ao norte. Na Figura 4 apresenta-se uma planta do complexo da barragem.

FIGURA 4 - PLANTA DO COMPLEXO ITAIPU.



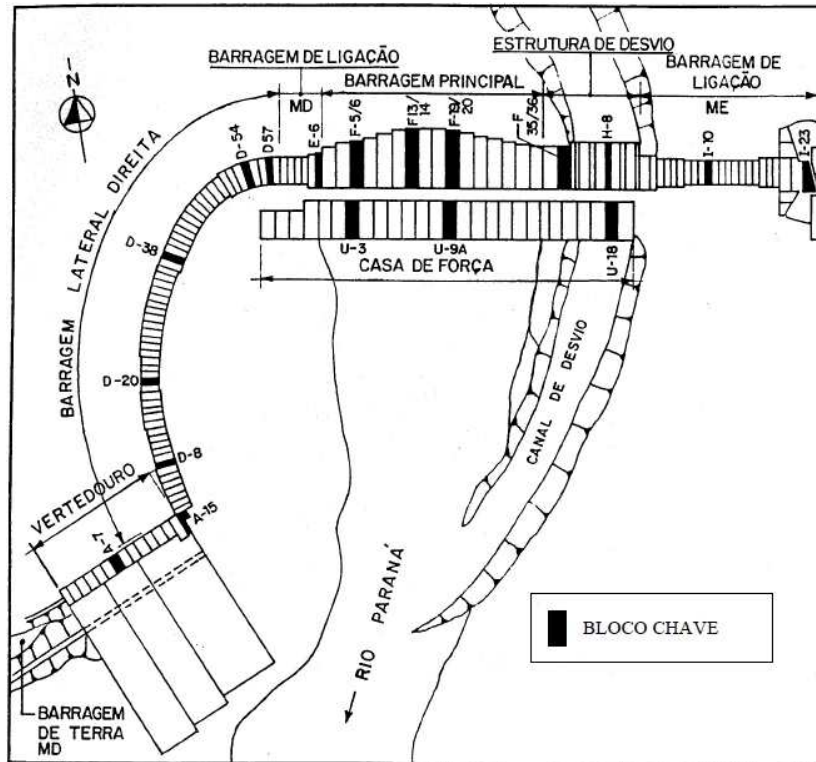
FONTE: ITAIPU Binacional (2015)

A Barragem Principal (trecho F) é composta de blocos de concreto do tipo gravidade aliviada com 16 tomadas de água para a geração de energia (item 5 da Figura 4). Este é o trecho com maior influência da variação do nível do reservatório. No Apêndice E apresenta-se de maneira simplificada, como ocorrem os movimentos de um bloco de concreto à gravidade.

O trecho F possui 18 blocos duplos que vão do F1/2 ao F35/36 sendo quatro deles, denominados blocos chave, intensamente instrumentados por serem os mais representativos (ITAIPU BINACIONAL, 2009). A Figura 5 apresenta o esquema dos blocos chave na barragem de Itaipu. Os blocos chave no trecho F são os blocos F5/6, F13/14, F19/20 e F35/36. Os blocos F13/14 e F19/20 são os mais altos blocos de gravidade aliviada. A presente tese considera o bloco F19/20 para análise.


A Figura 6, adiante, apresenta a seção de um bloco de concreto de gravidade aliviada com tomada d' água.

FIGURA 5 - ESQUEMA DE BLOCOS CHAVE NA BARRAGEM DE ITAIPU



FONTE: Matos (2002).

FIGURA 6 - SEÇÃO DE UM BLOCO DE CONCRETO DO TIPO GRAVIDADE ALIVIADA NO TRECHO F



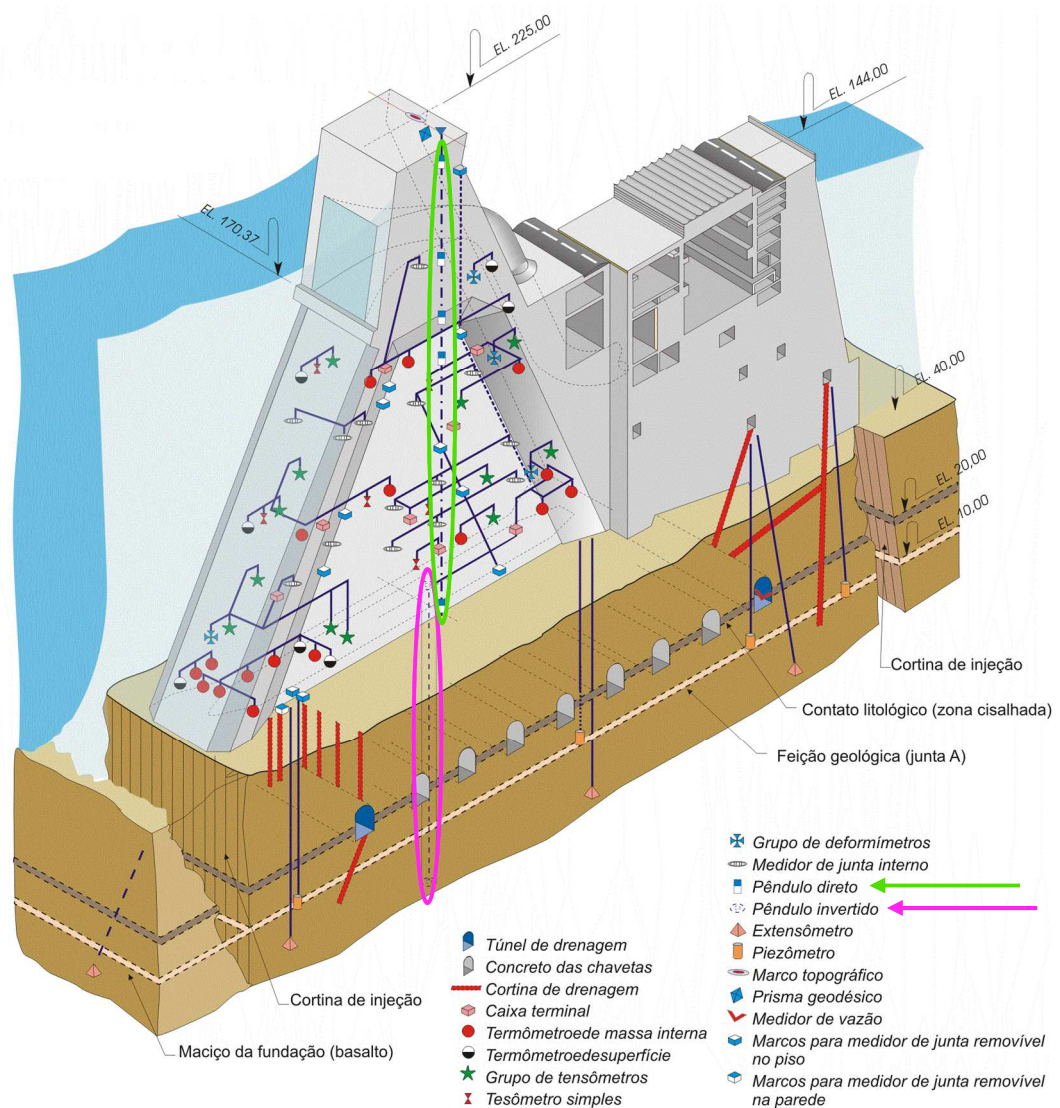
FONTE: ITAIPU Binacional (2014).

3.2 DADOS DA INSTRUMENTAÇÃO NA BARRAGEM DE ITAIPU

Itaipu conta com 2400 instrumentos (1358 no concreto, 881 nas fundações e 161 para geodesia), sendo 270 automatizados, e 5295 drenos (949 no concreto e 4346 nas fundações) para acompanhar o desempenho das estruturas de concreto e fundações (ITAIPU BINACIONAL, 2015).

Na Figura 7 tem-se uma representação de um bloco chave do trecho F com a respectiva instrumentação instalada.

FIGURA 7 - REPRESENTAÇÃO DE UM BLOCO CHAVE E INSTRUMENTAÇÃO INSTALADA



FONTE: Modificada de ITAIPU Binacional (2015).

Para analisar os dados da instrumentação, Itaipu desenvolveu módulos de monitoramento, os quais fazem parte do Sistema de Otimização e Análise de

Auscultação (SOAA). O sistema é composto por diversas aplicações de *softwares* e interfaces com outros sistemas externos (COELHO, PATIAS e GARAY, 2015). É composto por subsistemas de controle de segurança descritos no Quadro 1.

QUADRO 1 - DESCRIÇÃO DOS PRINCIPAIS SUBSISTEMAS DE CONTROLE DA SEGURANÇA ESTRUTURAL DA BARRAGEM DE ITAIPU

Subsistema	Descrição
SAT Sistema de Arquivo Técnico	Responsável pelo armazenamento e consulta de todos os documentos e projetos de ITAIPU.
SGM Sistema de Gestão de Medições Manuais	Responsável por introduzir e validar leituras de campo que são processadas através de fórmulas e transformadas em grandezas.
MD Maquete Digital	Permite de forma intuitiva navegar pela estrutura civil da barragem, obter gráficos e informações da instrumentação civil.
SAA Sistema Analítico de Auscultação	Sistema <i>online</i> de monitoramento que contém dados de alarme dos sensores com leituras manuais e automatizadas.
SGDP Sistema de Gestão de Dados Planimétricos	Responsável pela importação dos dados das campanhas planimétricas, processamento e geração de gráficos de monitoramento.
MS Mapa de Subpressão	Permite gerar mapas de distribuição das subpressões nas feições geológicas monitoradas por piezômetros.
SR Sistema de Recomendações	Sistema que realiza o gerenciamento das recomendações oriundas dos relatórios de análise estrutural da Barragem de Itaipu, permitindo acompanhar a situação da execução das recomendações.
PI	Plataforma do historiador de dados dos sistemas em tempo real da instrumentação de Itaipu.
ADAS Sistema de Aquisição de Dados Automáticos	Responsável por adquirir e armazenar diversas leituras de sensores de campo instalados na UHI.
MISTRAL	<i>Software</i> para análise qualitativa dos instrumentos automatizados para a análise do desempenho da barragem.
FIS Sistema de Fissuras	Realiza o registro e acompanhamento das fissuras. Sistema em fase de integração com o SOAA.

FONTE: Coelho, Patias e Garay (2015).

O Sistema Analítico de Auscultação (SAA) é um sistema *online* de monitoramento que contém dados de alarme dos sensores com leituras manuais e automatizadas. O módulo principal do SAA possui um sistema de alertas, que são definidos por cores conforme a seguinte descrição:

- Branca: Quando o valor máximo do período em análise encontra-se menor do que o período anterior, máximo histórico e máximo teórico;

- Verde: Quando ao se comparar um período com relação a outro, por exemplo, inverno de 2013 com inverno de 2014, o instrumento apresenta um alerta verde se o valor máximo do último inverno for maior que o valor máximo do inverno de 2013;
- Amarela: O instrumento recebe alerta amarelo quando o valor máximo do período analisado ultrapassar o máximo valor histórico;
- Vermelha: O alerta vermelho ocorre quando o valor máximo do período em análise ultrapassa o valor máximo teórico estabelecido no projeto.

O SAA realiza uma avaliação global de todos os instrumentos instalados na barragem e os agrupa conforme o nível de alerta. Além disso, possui filtros que permitem listar os instrumentos por nível de alerta, trecho, feição, tipo de instrumento, período, dentre outros. Este sistema também gera automaticamente um relatório, conforme os filtros utilizados pelo usuário (COELHO, PATIAS e GARAY, 2015).

O deslocamento é um dos parâmetros mais importantes no monitoramento de segurança de barragens, então a ênfase na instrumentação instalada no bloco chave F19/20 do trecho F se dá nos instrumentos pêndulos direto e invertido. Mais especificamente, consideram-se os sensores destes instrumentos que se localizam na base do bloco. Observa-se na Figura 7 (página 47) que o pêndulo direto possui outros sensores espaçados ao longo do comprimento do bloco.

Os pêndulos captam os movimentos relativos da estrutura (deslocamentos horizontais) que acontecem devido a fatores externos como variação do nível do reservatório e temperatura. Portanto, consideram-se para a análise as seguintes variáveis:

- Leituras do pêndulo direto;
- Leituras do pêndulo invertido;
- Leituras do nível do reservatório e
- Leituras da temperatura ambiente.


O banco de dados das leituras da instrumentação foi fornecido pelo Centro de Estudos Avançados em Segurança de Barragens – CEASB, obtido do Sistema de Aquisição de Dados Automáticos (ADAS). As leituras automatizadas dos sensores dos instrumentos estão disponíveis a partir de outubro de 2005 até os dias atuais, e são

realizadas a cada 30 minutos, porém considera-se neste trabalho a média diária dessas leituras, devido à periodicidade diária das leituras do nível do reservatório e da temperatura ambiente. O período de análise foi entre outubro de 2005 a novembro de 2015.

Os dados das leituras são de 4 sensores dos pêndulos instalados no bloco F19/20: dois sensores do pêndulo direto (variáveis pdx e pd_y) e dois sensores do pêndulo invertido (variáveis pix e pi_y). Também os valores observados para o nível do reservatório a montante (variável $nível$) e valores da temperatura ambiente (variável $temp$). No caso dos pêndulos, os dois sensores são referentes a medidas dos deslocamentos na direção x, no sentido do fluxo (direção montante-jusante) e, na direção y, perpendicular ao fluxo (margem direita-esquerda).

Para melhor compreensão da localização dos sensores considerados para análise, na Figura 8 estão em destaque os sensores dos pêndulos direto (denominação técnica COF22) e do pêndulo invertido (denominação técnica COF23) na base do bloco F19/20 que está na elevação 45 m acima do nível do mar.

FIGURA 8 - SENSORES DOS PÊNDULOS CONSIDERADOS PARA ANÁLISE



FONTE: CEASB-ITAIPU³ (2015).

3.3 MODELAGEM E PREVISÃO

Nesta seção é apresentada a metodologia proposta nesta tese que se divide basicamente em três fases.

A Fase 1 é denominada de análise univariada dos dados, sendo definida por:

³ Disponibilizada pelo Centro de Estudos Avançados em Segurança de Barragens da Itaipu Binacional.

- adequação da amostra quanto à periodicidade, leituras erradas e leituras ausentes;
- avaliação de pontos influentes na regressão;
- cálculo da estatística descritiva dos dados e
- teste da estacionariedade das séries.


A Fase 2 é denominada ajuste do modelo. Nesta fase os seguintes passos foram realizados:

- especificação da defasagem de cada variável no modelo;
- teste de diagnóstico do modelo;
- estimação dos parâmetros do modelo na forma de Bårdsen, ou seja, o ECM irrestrito;
- aplicação da abordagem *Bounds Testing*;
- estimação dos parâmetros do modelo ECM restrito (quando necessário) e
- teste de diagnóstico do modelo.

A última fase (Fase 3) consiste na previsão e se caracteriza por:

- cálculo das previsões h passos (dias) à frente fora da amostra;
- cálculo das medidas de avaliação dos erros para cada modelo;
- comparação das previsões e escolha do melhor modelo;
- cálculo dos limites inferiores e superiores para as previsões com base no modelo escolhido.

FIGURA 9 - METODOLOGIA PROPOSTA



FONTE: A autora (2016).

A seguir a descrição de cada Fase da metodologia proposta.

3.3.1 Fase 1

As leituras dos sensores dos pêndulos eram lidas e armazenadas a cada 30 minutos, no entanto, alguns dias apresentavam um número inferior de leituras esperado (48 leituras), outros dias não apresentavam nenhuma leitura. Assim, a adequação da amostra quanto à periodicidade foi realizada por meio do *script* “gmedia” e do *script* “gmedia.aus” em MATLAB (MATHWORKS, 2013). Os *scripts*, apresentados no Apêndice B, calculam a média diária das observações e depois completam a matriz com todas as datas, preenchendo as ausentes com o valor de 999999 para fácil identificação posterior.

Deve-se lembrar que a escolha da periodicidade diária foi devida à periodicidade das variáveis independentes nível do reservatório (*nível*) e temperatura ambiente (*temp*).

Com a matriz completa, foram analisados os casos de leituras erradas. Algumas médias diárias dos deslocamentos apresentavam valores muito distintos das demais. Quando investigados os dados originais, identificava-se a presença de valores como “9999” ou “-9999” nos dados, o que contribuía para aquele valor de média discrepante. Esses valores “9999” ou “-9999” correspondem a leituras erradas dos instrumentos que acontecem em casos isolados. A justificativa é que pode ter acontecido falha no sistema de aquisição de dados ou falha no sensor do instrumento.

Esses casos, quando ocorrem, são avaliados pelos técnicos e engenheiros responsáveis pela segurança da barragem, pois podem ser indicativos de necessidade de manutenção.

Por fim, na matriz completa, observaram-se as médias ausentes (valores “999999” identificados pelo *script*), ou seja, aqueles dias em que nenhuma leitura de deslocamento foi registrada. Para esses valores de dados ausentes, *a priori*, utilizou-se a nomenclatura NA. Todos os modelos apresentados no capítulo Análise e Discussão dos Resultados foram ajustados *à priori* considerando os dados ausentes, no entanto, a especificação e estabilidade dos modelos ficavam comprometidas, ou seja, a validação dos modelos não era obtida. Posteriormente, o preenchimento das lacunas foi realizado por interpolação e os modelos ajustados com as séries completas.

Para os dados referentes ao nível do reservatório e da temperatura do ar, não foi necessário nenhum tipo de adequação da amostra. As séries apresentavam todas as observações diárias no período analisado e ausência de leituras erradas.

A partir deste momento todos os procedimentos foram realizados com o uso do *software* Eviews 9 (IHS GLOBAL, 2015).

Quanto à avaliação de pontos influentes no modelo, observam-se possíveis *outliers*, principalmente em um dos sensores do pêndulo invertido. Observou-se também uma mudança de comportamento em um dos sensores do pêndulo direto no ano de 2012. Estes aspectos foram analisados com estatísticas que medem a influência de alguns pontos no modelo. Opta-se pela retirada dos pontos considerados influentes e *outliers*. As estatísticas utilizadas foram o resíduo studentizado e a *DFFIT*.

O resíduo studentizado é o resíduo da equação em que a observação *i* foi retirada dividido por uma estimativa de seu desvio padrão, ou seja,

$$r_i = \frac{e_{(i)}}{s(i)\sqrt{1-h_i}}$$

onde $e_{(i)}$ é o resíduo considerando a observação *i* retirada, $s(i)$ é a variância dos resíduos quando a observação *i* não está incluída na estimação e h_i é o *i*-ésimo elemento da diagonal da matriz de projeção $H = X(X'X)^{-1}X'$. Este elemento da diagonal da matriz *H* mede a importância da *i*-ésima observação na determinação do ajuste. Observações que apresentem valores maiores do que 3 para os resíduos

studentizados são consideradas *outliers*, mas existem pesquisas que consideram o limite 2 para o valor absoluto do resíduo studentizado.

A estatística *DFFIT* mede a influência no valor ajustado com a retirada da i -ésima observação, definido por

$$DFFIT_i = \left[\frac{h_i}{1-h_i} \right]^{1/2} \frac{e_i}{s(i)\sqrt{1-h_i}}$$

Valores absolutos excedendo $2\sqrt{p/n}$ indicam observações influentes.

Após a análise dos pontos influentes e dos *outliers*, calcula-se a estatística descritiva dos dados. Aqui se utilizou já a série completa das variáveis, com 3687 observações, assim como nas fases seguintes.

Posteriormente, a estacionariedade das séries foi verificada pelo teste ADF (Augmented Dickey-Fuller). Este teste é conhecido por teste de raiz unitária, uma vez que a hipótese nula é a presença de raiz unitária, ou seja, a série é não estacionária. O teste ADF assume que os dados são gerados por um processo autorregressivo de ordem p e o teste é, portanto, baseado no ajuste de uma regressão de mesma ordem. No teste é inserida uma correção paramétrica para as correlações de ordem superior, assumindo que a série segue um processo AR(p) e adicionar termos defasados da diferença da variável dependente no lado direito da regressão de teste. As regressões de teste são dadas por:

Modelo 1:

$$\Delta y_t = \delta y_{t-i} + \sum_{j=1}^p a_j \Delta y_{t-j} + \varepsilon_t \quad (30)$$

Modelo 2:

$$\Delta y_t = c + \delta y_{t-i} + \sum_{j=1}^p a_j \Delta y_{t-j} + \varepsilon_t \quad (31)$$

Modelo 3:

$$\Delta y_t = c + \beta t + \delta y_{t-i} + \sum_{j=1}^p a_j \Delta y_{t-j} + \varepsilon_t \quad (32)$$

onde c é a constante e o termo βt é o termo de tendência linear. A hipótese nula e alternativa do teste são dadas por: $H_0 : \delta = 0$; $H_1 : \delta < 0$. Há duas questões sobre o teste. Primeiro, qual o número de defasagens do modelo (p) e segundo, qual dos modelos acima utilizar (equações 31, 32 ou 33) (LI, WANG e LIU, 2013).

Para o número de defasagens (p) utiliza-se o critério de informação de Akaike (AIC) e sobre a escolha do modelo utiliza-se a seguinte ideia: se os resultados do teste de todos os três modelos (equações 31, 32 ou 33) não rejeitarem a hipótese nula, isso indica a presença de uma raiz unitária. Os valores críticos utilizados aqui são de Mackinnon (1996) que apresenta os cálculos dos valores críticos de Dickey-Fuller para tamanhos de amostra arbitrárias.

3.3.2 Fase 2

A Fase 2 consiste no ajuste e validação do modelo para fins da Fase 3.

Primeiramente, muitos modelos ADL são simulados com variação das defasagens⁴ na variável dependente e independente. Para cada modelo ADL ajustado calculam-se os critérios de informação. Optou-se pelo critério AIC, pois o uso de outros critérios resultava em modelos bem mais parcimoniosos, no entanto, os resíduos destes modelos apresentavam autocorrelação.

Determinado o número de defasagens do modelo $ADL(r, s_1, s_2)$ pelo critério AIC, o teste RESET foi calculado para verificar mal especificação do modelo e o teste de autocorrelação de Breusch-Godfrey (descritos na seção 2.4). O modelo ADL para um sensor do pêndulo é dado por

$$sensor_t = \mu + \sigma t + \sum_{i=1}^r \alpha_i sensor_{t-i} + \sum_{i=0}^{s_1} \beta_i nível_{t-i} + \sum_{i=0}^{s_2} \phi_i temp_{t-i} + \varepsilon_t \quad (33)$$

Se válidos os testes acima no modelo $ADL(r, s_1, s_2)$, pode-se estimar os parâmetros do modelo ECM irrestrito que é reparametrização do modelo ADL na forma de Bårdsen, dado por

⁴ O número máximo de defasagens do *software* EvIEWS 9 é 12.

$$\Delta sensor_t = \sum_{i=1}^{r-1} \delta_i \Delta sensor_{t-i} + \sum_{i=0}^{s_1-1} \gamma_i \Delta nível_{t-i} + \sum_{i=0}^{s_2-1} \eta_i \Delta temp_{t-i} + \theta_0 sensor_{t-1} + \theta_1 nível_{t-1} + \theta_2 temp_{t-1} + \mu + \sigma t + \varepsilon_t \quad (34)$$

Com os coeficientes estimados do ECM irrestrito, o *Bounds Testing* é aplicado para verificar evidências de relação de longo prazo entre as variáveis, ou seja, realiza-se o teste F para a significância conjunta dos coeficientes das séries das variáveis defasadas ($H_0 : \theta_0 = \theta_1 = \theta_2 = 0$ contra a alternativa de que ao menos um dos θ_i é não nulo). Se o resultado no passo anterior é positivo, a relação de longo prazo é estimada para as séries das variáveis em nível (variável original). A relação de longo prazo é dada por

$$sensor_t = \mu + \sigma t + \alpha_1 nível_t + \alpha_2 temp_t + v_t \quad (35)$$

Estima-se o ECM restrito dado por

$$\Delta sensor_t = \sum_{i=1}^{r-1} \delta_i \Delta sensor_{t-i} + \sum_{i=0}^{s_1-1} \gamma_i nível_t + \sum_{i=0}^{s_2-1} \eta_i temp_t + \lambda(v_{t-1}) + \varepsilon_t \quad (36)$$

e valida-se o modelo com os testes RESET e Breusch-Godfrey.

3.3.3 Fase 3

A última fase consiste na previsão. Esta foi realizada fora da amostra na abordagem dinâmica. Com a escolha da abordagem dinâmica (vários passos à frente), se verificado comportamento anômalo nas leituras dos sensores, existe um tempo hábil para uma investigação e possível intervenção dos engenheiros e técnicos responsáveis pela segurança da estrutura.

O horizonte de previsão escolhido foi $h=7, 14, 28, 61$ dias, correspondentes a 1 semana, 2 semanas, 1 mês e 2 meses. Essas previsões foram comparadas com a parte final da amostra separada como conjunto de teste. Um horizonte maior poderia ser adotado, mas o erro de previsão aumenta e considera-se 2 meses tempo hábil para uma possível intervenção dos engenheiros.

Os resultados da previsão dinâmica serão comparados para os modelos ECM irrestrito, ECM restrito, ARIMA e VAR⁵ e as medidas para avaliar o erro de previsão foram o RMSE e o MAPE. No Apêndice C segue uma breve descrição sobre os modelos ARIMA e VAR.

Após obter as previsões para todos os modelos e calcular as medidas de avaliação dos erros opta-se por um dos modelos para calcular os limites inferiores e superiores do intervalo de confiança, utilizando o erro padrão da média da seguinte forma:

- 1) espera-se que 95% dos valores encontrem-se a uma distância da média inferior a duas vezes o erro padrão (denotada na expressão por “se”), então os limites serão dados por $\hat{y}_t \pm 2se$, e
- 2) espera-se que 99,7% dos valores encontrem-se a uma distância da média inferior a três vezes o erro padrão, então os limites serão dados por $\hat{y}_t \pm 3se$.

Se o valor observado ultrapassar os limites do item 1, considera-se um estado de atenção e, se o valor observado ultrapassar os limites do item 2, considera-se um estado de alerta. Se o estado de atenção não perdurar ao longo dos dias, significa que a variabilidade dos dados voltou à normalidade. Se o estado de atenção perdurar, é indicado avaliar as possíveis causas. Entretanto, em caso de alerta, indica-se uma investigação.

Assim, propõe-se uma nova metodologia para fornecer limites aos dados de instrumentação, que possa futuramente complementar o sistema de alarme já existente em Itaipu, o SAS.

⁵ O modelo HTT não foi utilizado para comparação porque as leituras dos termômetros de concreto são realizadas mensalmente pelos técnicos, assim, são dados de periodicidade diferente das leituras que já foram automatizadas.

4 ANÁLISE E DISCUSSÃO DOS RESULTADOS

Neste capítulo, a seção 4.1 apresenta os dados, as estatísticas descritivas e os testes de estacionariedade que antecedem a modelagem. Posteriormente, as seções 4.2 a 4.5 apresentam os modelos autorregressivos de defasagens distribuídas estimados para os deslocamentos relativos dos pêndulos direto e invertido, seguindo os seguintes passos: estimação do ECM irrestrito, *Bounds Testing*, estimação do ECM restrito e previsão.

4.1 ANÁLISE UNIVARIADA DOS DADOS

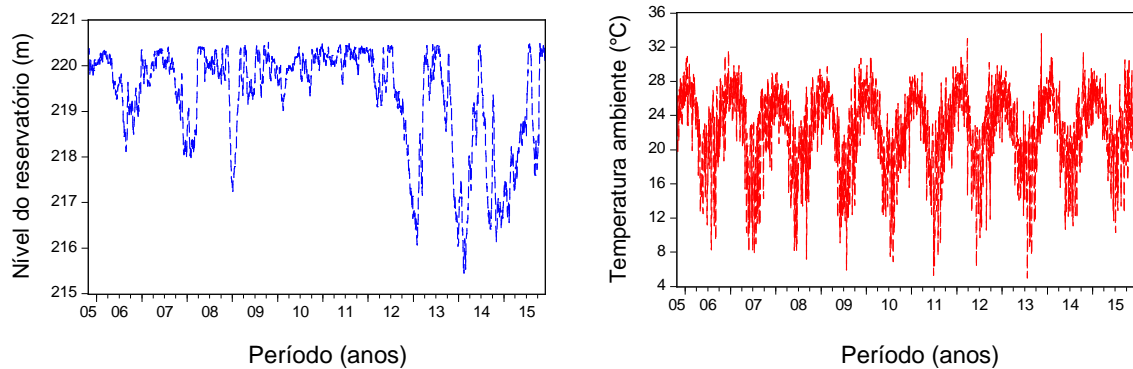
Os dados foram obtidos pelo sistema ADAS que Itaipu dispõe desde 2005. Os instrumentos que foram automatizados passaram a ter leituras a cada 30 minutos, além das leituras por inspeção visual já existentes. A presente análise considera as leituras automatizadas dos sensores do pêndulo direto e invertido que mensuram deslocamentos horizontais (direção do fluxo e normal ao fluxo) do bloco F19/20 e também as leituras do nível do reservatório e da temperatura ambiente.

Como variáveis dependentes em cada modelo tem-se deslocamentos na direção do fluxo obtidos pelo pêndulo direto (pdx) e pelo pêndulo invertido (pix), e, deslocamentos na direção normal ao fluxo obtidos pelo pêndulo direto (pdy) e pelo pêndulo invertido (piy). Para estas variáveis, calculou-se a média diária das leituras, pois as variáveis independentes, leituras do nível do reservatório e temperatura ambiente, têm periodicidade diária. O período de dados disponível para a análise foi do dia 27 de outubro de 2005 a 30 de novembro de 2015, totalizando amostras de 3687 observações para cada variável⁶.

Na Figura 10 apresentam-se os gráficos das variáveis independentes e na Figura 11 apresentam-se os gráficos das variáveis dependentes. Observam-se na Figura 11 possíveis *outliers*, principalmente na variável pix, quando no gráfico destacam-se 12 pontos discrepantes. Outro aspecto relevante é uma mudança de comportamento no sensor pdy aproximadamente no ano de 2012. Estes aspectos serão analisados a seguir com estatísticas que avaliam pontos influentes na regressão.

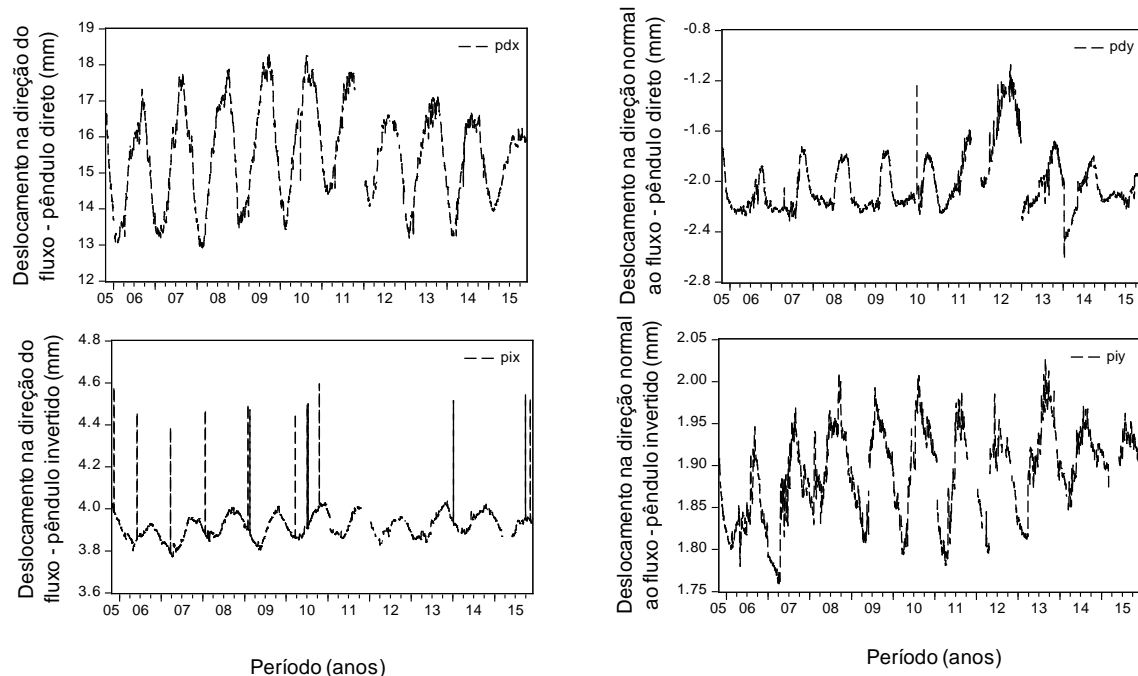
⁶ Dados ausentes foram preenchidos por meio de interpolação linear.

FIGURA 10 - VARIÁVEIS INDEPENDENTES



FONTE: A autora (2016).

FIGURA 11 - VARIÁVEIS DEPENDENTES



FONTE: A autora (2016).


Nas séries das variáveis *pdx* e *piy* não foram encontrados pontos influentes que poderiam ser considerados como *outliers* segundo as estatísticas *DFFITS* e os resíduos *studentizados*.

Na série *pdy* os pontos referentes às datas de 28/06/2010 e 09/01/2014 foram considerados pontos influentes segundo os resíduos *studentizados*, juntamente com todos os meses de 2012 que se apresentaram fora dos limites considerados (Figura 12). A estatística *DFFITS* também apresenta estes pontos e o ano de 2012 como pontos influentes, no entanto, apresenta pontos além destes. Opta-se por considerar os pontos comuns entre as duas estatísticas como pontos influentes. Para esta

variável *pdy* o conjunto de treinamento e de teste será distinto dos demais sensores e o objetivo também será outro.

Para o sensor *pdy*, a modelagem foi realizada com o seguinte objetivo: Será que o modelo é capaz de reconhecer previamente o período incomum? Utilizando os dados até o período em que o comportamento das leituras do sensor permanecera estável: Será que o modelo poderia alertar previamente sobre as leituras anômalas do sensor no ano de 2012? É o que se espera. Ou seja, esperam-se observações fora do intervalo de confiança determinado pelo modelo, confirmando sua utilidade.

FIGURA 12 - RESÍDUOS STUDENTIZADOS DA REGRESSÃO COM A VARIÁVEL PDY




FONTE: A autora (2016).

Na série *pix* os pontos influentes são mais facilmente determinados. Nas duas estatísticas, os pontos foram os mesmos e coincidem com os pontos que se destacam no gráfico da série. A Figura 13 apresenta os resíduos *studentizados* e a estatística *DFFITS* que destacam os mesmos pontos como influentes. Com a retirada desses 13 pontos e a substituição por valores ausentes, que posteriormente foram preenchidos por interpolação, pretende-se melhorar o ajuste do modelo para fins de previsão.

A Tabela 1 apresenta as estatísticas descritivas das variáveis já com as séries dos sensores dos pêndulos completas. A interpolação linear para preenchimento dos dados ausentes não alterou significativamente as estatísticas descritivas.

FIGURA 13 - PONTOS INFLUENTES NA REGRESSÃO DA VARIÁVEL PIX



FONTE: A autora (2016).

TABELA 1 - ESTATÍSTICAS DESCRITIVAS

Estatísticas	pdx (mm)	pdv (mm)	pix (mm)	piy (mm)	nível (m)	temp (°C)
Média	15,52	-2,08	3,92	1,89	219,32	22,27
Mediana	15,63	-2,14	3,91	1,9	219,76	23,00
Máximo	18,27	-1,59	4,03	2,03	220,52	33,6
Mínimo	12,88	-2,32	3,77	1,76	215,45	5,00
Desvio padrão	1,31	0,16	0,05	0,05	1,13	4,66
Assimetria	-0,05	0,94	0,01	-0,23	-1,24	-0,81
Curtose	2,04	2,65	2,19	2,28	3,58	3,34
Observações	3687	2187 ⁷	3687	3595 ⁸	3687	3687

FONTE: A autora (2016).

Quanto à estacionariedade foi realizado o teste ADF (Augmented Dickey-Fuller). Observa-se na Tabela 2 que as variáveis *piy*, *nível* e *temp* são estacionárias. As variáveis *pdx*, *pdv* e *pix* são integradas de ordem um, $I(1)$. O teste aponta fortemente que nenhuma das variáveis é $I(2)$. Essa miscelânea de séries estacionárias e $I(1)$ favorecem a utilização da abordagem *Bounds Testing*, uma vez que essa abordagem admite tal situação e é robusta a possíveis falhas dos testes de raiz unitária (ARONE, 2014).

⁷ Para a variável *pdv* a amostra é do dia 27/10/2005 até o dia 16/10/2011 (ver página 81 e 82).

⁸ Para a variável *piy* a amostra é do dia 27/10/2005 até o dia 30/08/2015 (ver página 70).

TABELA 2 - TESTES DE RAÍZES UNITÁRIAS⁹

Variáveis		Estatística t do teste ADF		
		Modelo 3	Modelo 2	Modelo 1
Variável Dependente	pdx	-2,47 (0,34)	-2,43 (0,13)	-0,32 0,57
	Δpdx	-33,08 (0,00)		
	pdv	-2,91 (0,16)	-2,34 (0,16)	-0,3 (0,58)
	Δpdv	-30,99 (0,00)		
	pix	-3,29 (0,07)	-2,9 (0,05)	-0,28 (0,59)
	Δpix	-37,27 (0,00)		
	piy	-4,41 (0,00)		
Variável Independente	nível	-3,9 (0,01)	-3,63 (0,00)	
	temp	-6,12 (0,00)		
Valores Críticos	1%	-3,96	-3,43	-2,57
	5%	-3,41	-2,86	-1,94
	10%	-3,13	-2,57	-1,62

FONTE: A autora (2016).

4.2 MODELO PARA A VARIÁVEL DEPENDENTE PIX

A amostra foi separada em um conjunto de treinamento e outro conjunto para teste. O primeiro foi utilizado para estimação do modelo e consiste nas observações de 27/10/2005 a 30/09/2015 e o outro foi utilizado para avaliação do erro e consiste nas observações de 01/10/2015 a 30/11/2015. Neste modelo adota-se o número doze como máximo de defasagens para a variável *pix* e para as variáveis *nível* e *temp*.


Foram avaliados 2028 modelos pelo *software* Eviews 9. Pelo critério AIC o modelo ótimo selecionado foi o *ADL*(12, 7, 12), onde 12 é a ordem de defasagem da variável dependente *pix*, 7 é a ordem de defasagem da variável *nível* e, por fim, 12 é a ordem de defasagem da variável *temp*. O modelo é dado pela seguinte equação

$$pix_t = \sum_{i=1}^{12} \alpha_i pix_{t-i} + \sum_{i=0}^7 \beta_i nível_{t-i} + \sum_{i=0}^{12} \phi_i temp_{t-i} + \varepsilon_t \quad (37)$$

⁹ O teste ADF foi realizado para o conjunto de treinamento de cada variável dependente.

O teste RESET com estatística $F_{(2,3579)}=2,1$ e valor-p de 0,12 não rejeita a hipótese nula de correta especificação do modelo. Os testes de autocorrelação Breusch-Godfrey corroboram a hipótese nula de ausência de autocorrelação nos resíduos ($LM_{(12)}=9,53$ e valor-p 0,66). A Figura 14 apresenta o gráfico das previsões realizadas pelo modelo $ADL(12,7,12)$ dentro da amostra, os valores observados e os resíduos. O maior resíduo foi registrado para o dia 15/06/2012 no valor de -0,04, daí a dificuldade de se distinguir o valor observado do valor previsto no gráfico (Figura 14).

FIGURA 14 - GRÁFICO DO MODELO ADL NO CONJUNTO DE TREINAMENTO PARA PIX



FONTE: A autora (2016).

Devido à presença de multicolinearidade, apresentada no Apêndice A, recorreu-se ao modelo ADL na forma de Bärdsen para a estimação dos parâmetros. A forma de Bärdsen atenua problemas de multicolinearidade frequentes no modelo ADL original. O modelo ADL na forma de Bärdsen

$$\Delta pix_t = \theta_1 pix_{t-1} + \theta_2 nível_{t-1} + \theta_3 temp_{t-1} + \sum_{i=1}^{11} \delta_i \Delta pix_{t-i} + \sum_{i=0}^6 \gamma_i \Delta nível_{t-i} + \sum_{i=0}^{11} \eta_i \Delta temp_{t-i} + \varepsilon_t \quad (38)$$

Na Tabela 3 encontram-se os coeficientes estimados por mínimos quadrados ordinários do modelo $ADL(12,7,12)$ na forma de Bårdsen ou o ECM irrestrito. O modelo não inclui constante e o termo de tendência, pois estes não apresentaram significância estatística. No entanto, algumas defasagens das variáveis foram mantidas para efeitos de ajuste. De fato, com a retirada de algumas destas defasagens não significativas perdeu-se alguma propriedade relevante para fins de previsão como, por exemplo, a ausência de autocorrelação nos resíduos.

TABELA 3 - MODELO ECM IRRESTRITO PARA A VARIÁVEL DEPENDENTE PIX

Preditores	Coeficiente	Erro Padrão	Estatística t	Valor-p
nível _{t-1}	0,000056	0,000016	3,474509	0,00
temp _{t-1}	-0,000206	0,000017	-12,131430	0,00
pix _{t-1}	-0,001959	0,000903	-2,169779	0,03
Δ pix _{t-1}	0,306760	0,016729	18,337420	0,00
Δ pix _{t-2}	-0,067870	0,017510	-3,876034	0,00
Δ pix _{t-3}	-0,053882	0,017556	-3,069203	0,00
Δ pix _{t-4}	-0,034641	0,017578	-1,970663	0,05
Δ pix _{t-5}	-0,022444	0,017596	-1,275494	0,20
Δ pix _{t-6}	-0,032118	0,017422	-1,843472	0,06
Δ pix _{t-7}	0,006245	0,017421	0,358482	0,72
Δ pix _{t-8}	-0,017699	0,017398	-1,017276	0,31
Δ pix _{t-9}	-0,006758	0,017381	-0,388797	0,70
Δ pix _{t-10}	-0,029524	0,017318	-1,704801	0,09
Δ pix _{t-11}	-0,031189	0,016477	-1,892959	0,06
Δ nível	-0,004891	0,000957	-5,111753	0,00
Δ nível _{t-1}	0,007213	0,001167	6,181802	0,00
Δ nível _{t-2}	0,001466	0,001174	1,248697	0,21
Δ nível _{t-3}	-0,001188	0,001175	-1,011606	0,31
Δ nível _{t-4}	0,001826	0,001175	1,554344	0,12
Δ nível _{t-5}	0,001308	0,001173	1,115076	0,26
Δ nível _{t-6}	-0,002730	0,000968	-2,820286	0,00
Δ temp	-0,000088	0,000023	-3,777540	0,00
Δ temp _{t-1}	0,000129	0,000027	4,793299	0,00
Δ temp _{t-2}	0,000156	0,000027	5,727608	0,00
Δ temp _{t-3}	0,000123	0,000027	4,533335	0,00
Δ temp _{t-4}	0,000074	0,000027	2,745404	0,01
Δ temp _{t-5}	0,000095	0,000027	3,514551	0,00
Δ temp _{t-6}	0,000074	0,000027	2,771728	0,01
Δ temp _{t-7}	0,000014	0,000026	0,547460	0,58
Δ temp _{t-8}	0,000074	0,000025	2,936212	0,00
Δ temp _{t-9}	0,000038	0,000025	1,554218	0,12
Δ temp _{t-10}	0,000045	0,000023	1,906594	0,06
Δ temp _{t-11}	0,000059	0,000023	2,526083	0,01

FONTE: A autora (2016).

O modelo apresentou a estatística de Durbin-Watson igual a 2,00, o erro padrão da regressão foi de 0,003 e o coeficiente de determinação ajustado (R^2 ajustado) de 0,19, que embora pequeno, quando calculado para a variável *pix*, utilizando o valor previsto pelo ECM irrestrito, resulta um R^2 ajustado no valor de 0,99. Os testes de autocorrelação de Breusch-Godfrey corroboram a hipótese nula de ausência de autocorrelação nos resíduos ($LM_{(12)}=9,53$ e valor-p 0,66). Na ausência de autocorrelação, pode ser utilizada a abordagem *Bounds Testing*.

Estimado o modelo ECM irrestrito (Tabela 3), passa-se à fase de verificação da existência de cointegração, ou seja, se existe ou não um relacionamento a longo prazo entre as temperaturas e nível do reservatório com o deslocamento na direção do fluxo mensurado pelo pêndulo invertido. Para isso, efetua-se o teste F de significância conjunta dos coeficientes referentes aos regressores defasados um período, nomeadamente pix_{t-1} , $nível_{t-1}$ e $temp_{t-1}$. A hipótese nula de nulidade conjunta dos coeficientes significa que não existe relação de equilíbrio a longo prazo.

O valor da estatística F foi de 52,34 com valor-p de 0,00. Recorrendo aos valores críticos propostos por Pesaran, Shin e Smith (2001), para um modelo que não inclui constante e termo de tendência, o valor da estatística F excede o limite superior mesmo ao nível de 1% de significância que tem como limites 3,88 e 5,3. Portanto, há evidências de relação de equilíbrio de longo prazo ao rejeitar fortemente a hipótese nula.

É importante testar também a nulidade do coeficiente de pix_{t-1} (o teste ECM) contra a alternativa de que o mesmo é menor que zero que corresponde a condição necessária de estabilidade do modelo. O valor da estatística F é de 4,7 com valor-p de 0,03, ou seja, rejeita-se a hipótese nula reforçando o resultado anterior de existência de relação de equilíbrio de longo prazo.

Para estimar o ECM restrito é necessário estimar a relação estática, ou seja, estimar os coeficientes da relação de equilíbrio de longo prazo. Neste modelo, os parâmetros são estimados consistentemente por mínimos quadrados ordinários. A relação estática é dada por

$$pix_t = \alpha_1 nível + \alpha_2 temp + v_t \quad (39)$$

e as estimativas são dadas na Tabela 4. Como interessa o modelo dinâmico de curto prazo para fins de previsão, passa-se à estimação do modelo ECM restrito.

A equação (40) ou o ECM restrito indica a variação de curto prazo de deslocamentos na direção do fluxo (radiais) influenciados pela variação do nível do reservatório e de temperatura ambiente. Por exemplo, se o deslocamento radial se afasta do equilíbrio de longo prazo, o desequilíbrio de curto prazo vai ser restaurado para o equilíbrio, devido ao coeficiente λ que deve ter sinal negativo. A Tabela 4 apresenta o ECM restrito também conhecido como método de dois passos de Engle-Granger.

$$\Delta pix_t = \sum_{i=1}^{r-1} \delta_i \Delta pix_{t-i} + \sum_{i=0}^{s_1-1} \gamma_i \Delta nível_{t-i} + \sum_{i=0}^{s_2-1} \eta_i \Delta temp_{t-i} + \lambda(v_{t-1}) + \varepsilon_t \quad (40)$$

TABELA 4 - MODELO ECM RESTRITO PARA A VARIÁVEL DEPENDENTE PIX

(continua)

Coeficientes de longo prazo				
Preditores	Coeficiente	Erro Padrão	Estatística t	Valor-p
nível	0,017747	0,000020	833,0000	0,00
temp	0,001066	0,000205	5,192184	0,00
Coeficientes do ECM restrito				
Preditores	Coeficiente	Erro Padrão	Estatística t	Valor-p
v_{t-1}	-0,002281	0,001003	-2,273903	0,02
Δpix_{t-1}	0,347697	0,016735	20,776420	0,00
Δpix_{t-2}	-0,041101	0,017737	-2,317262	0,02
Δpix_{t-3}	-0,024677	0,017759	-1,389540	0,16
Δpix_{t-4}	-0,003513	0,017760	-0,197804	0,84
Δpix_{t-5}	0,011339	0,017743	0,639087	0,52
Δpix_{t-6}	0,000370	0,017583	0,021046	0,98
Δpix_{t-7}	0,038616	0,017582	2,196337	0,03
Δpix_{t-8}	0,013461	0,017572	0,766070	0,44
Δpix_{t-9}	0,022466	0,017578	1,278073	0,20
Δpix_{t-10}	-0,003662	0,017550	-0,208661	0,83
Δpix_{t-11}	0,008365	0,016505	0,506776	0,61
$\Delta nível$	-0,004764	0,000977	-4,876736	0,00
$\Delta nível_{t-1}$	0,007506	0,001190	6,305382	0,00
$\Delta nível_{t-2}$	0,001530	0,001198	1,277059	0,20
$\Delta nível_{t-3}$	-0,001094	0,001199	-0,912336	0,36
$\Delta nível_{t-4}$	0,001856	0,001199	1,547910	0,12
$\Delta nível_{t-5}$	0,001230	0,001197	1,027366	0,30
$\Delta nível_{t-6}$	-0,003002	0,000986	-3,043786	0,00
$\Delta temp$	-0,000055	0,000024	-2,336457	0,02
$\Delta temp_{t-1}$	-0,000035	0,000024	-1,477979	0,14
$\Delta temp_{t-2}$	0,000005	0,000025	0,206146	0,84

				(conclusão)
$\Delta temp_{t-3}$	-0,000016	0,000025	-0,613396	0,54
$\Delta temp_{t-4}$	-0,000051	0,000026	-1,978151	0,05
$\Delta temp_{t-5}$	-0,000016	0,000026	-0,602681	0,55
$\Delta temp_{t-6}$	-0,000024	0,000026	-0,925546	0,35
$\Delta temp_{t-7}$	-0,000070	0,000026	-2,735806	0,01
$\Delta temp_{t-8}$	0,000006	0,000025	0,225105	0,82
$\Delta temp_{t-9}$	-0,000017	0,000025	-0,676500	0,50
$\Delta temp_{t-10}$	0,000004	0,000024	0,170712	0,86
$\Delta temp_{t-11}$	0,000025	0,000024	1,054615	0,29

FONTE: A autora (2016).

Os preditores tem capacidade significativa para explicar Δpi_{it} , uma vez que a estatística F no valor de 21,7 (valor-p de 0,00), rejeita a hipótese nula de significância conjunta das estimativas. Assim como no ECM irrestrito, algumas estimativas apresentaram valor-p inferior a 0,05, no entanto foram mantidas para melhorar o nível de especificação do modelo. O erro padrão da regressão foi de 0,003, o coeficiente de determinação de 0,16 e a estatística Durbin-Watson igual a 2,0.

A estimativa do coeficiente de ajustamento de curto prazo para o equilíbrio é estatisticamente significativa e apresenta sinal negativo esperado ($\lambda = -0,002281$). Isto é importante, pois apoia a aceitação de cointegração estabelecida anteriormente. Por fim, em relação ao diagnóstico do modelo, o teste Breusch-Godfrey corrobora a hipótese nula de ausência de autocorrelação nos resíduos ($LM_{(5)}=5,3$ e valor-p 0,38).

4.2.1 Previsão

Em aplicações de modelagem de séries temporais, muitas vezes há interesse nas previsões, no entanto, os erros na previsão são inevitáveis, uma vez que não se tem informações sobre inovações ou choques futuros e nunca se conhece o verdadeiro processo de geração de dados. Logo, cabe ao pesquisador, diante de uma variedade de modelos, escolher o modelo que melhor descreva a série em estudo e que minimize o erro de previsão.

A Tabela 5 apresenta as medidas de avaliação dos erros dos modelos ECM irrestrito, ECM restrito, ARIMA e VAR para os horizontes de previsão $h=7$ (01/10/2015 a 07/10/2015), $h=14$ (01/10/2015 a 14/10/2015), $h=28$ (01/10/2015 a 28/10/2015) e $h=61$ (01/10/2015 a 30/11/2015).

TABELA 5 - MEDIDAS DE AVALIAÇÃO DOS ERROS.

Previsão h dias a frente	ECM irrestrito		ECM restrito		ARIMA(2,1,3)		VAR(3)	
	RMSE	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE	MAPE
h=7	0,0023	0,0468%	0,0028	0,0534%	0,0015	0,0313%	0,0026	0,0505%
h=14	0,0052	0,1028%	0,0097	0,1879%	0,0081	0,1468%	0,0094	0,1783%
h=28	0,0043	0,0849%	0,0124	0,2761%	0,0068	0,1293%	0,0118	0,2611%
h=61	0,0059	0,1170%	0,0175	0,4037%	0,0106	0,2235%	0,0141	0,3202%

FONTE: A autora (2016).

Foram construídos os gráficos das previsões de todos os modelos para comparação (Figura 15). O modelo ARIMA apresentou uma previsão praticamente constante, bem distinto das observações reais do sensor do pêndulo invertido. As previsões dos modelos ECM restrito e VAR são muito semelhantes até o horizonte de previsão 28 dias, mas diferem das observações reais do pêndulo invertido. As previsões do modelo ECM irrestrito foram as que acompanharam a tendência das observações reais, embora visualmente não tenha comportamento semelhante, e, apresentou medidas de avaliação de erro mais satisfatórias.

Portanto, para o ECM irrestrito foi construído o intervalo de confiança. A Figura 16 apresenta os limites de estado de atenção para o sensor do pêndulo invertido, as previsões e as observações reais do conjunto de teste. Nota-se que os valores observados não ultrapassam os limites do estado de atenção ($\hat{y}_t \pm 2se$), evidenciando que, para esse horizonte de previsão, as leituras do instrumento continuaram a comportar-se como no passado.

FIGURA 15 - PREVISÕES DOS MODELOS PARA O SENSOR PIX (HORIZONTE H=61 DIAS)





FIGURA 16 - INTERVALO DE CONFIANÇA PARA AS OBSERVAÇÕES DO SENSOR PIX



4.3 MODELO PARA A VARIÁVEL DEPENDENTE PIY

A amostra foi separada de forma diferente do modelo anterior, pois haviam dados ausentes no período posterior ao dia 30/08/2015, sendo assim, inviável considerar esse período para compor o conjunto de teste. Logo, o conjunto de treinamento utilizado para estimação do modelo foi o de 27/10/2005 a 30/06/2015 e o conjunto de teste utilizado para avaliação do erro foi de 01/07/2015 a 30/08/2015.

O teste ADF de estacionariedade para a amostra de treinamento apontou que as séries *piy*, *nível* e *temp* são estacionárias (Tabela 2), assim a abordagem *Bounds Testing* não será necessária.

Adota-se o número doze como máximo de defasagens das variáveis dependente (*piy*) e independentes (*nível*, *temp*). Foram avaliados 2028 modelos pelo *software* Eviews 9. Pelo critério AIC o modelo ótimo selecionado foi o *ADL*(12, 3, 10), onde 12 (doze) é a defasagem da variável dependente *piy*, 3 (três) é a defasagem da variável *nível* e, por fim, 10 (dez) é a defasagem da variável *temp*. O modelo é dado pela seguinte equação


$$piy_t = \mu + \sigma t + \sum_{i=1}^r \alpha_i piy_{t-i} + \sum_{i=0}^{s_1} \beta_i nível_{t-i} + \sum_{i=0}^{s_2} \phi_i temp_{t-i} + \varepsilon_t \quad (41)$$

Quanto ao diagnóstico do modelo, o teste RESET com estatística $F_{(2,3491)}=2,8$ e valor-p de 0,06 não rejeita a hipótese nula de correta especificação do modelo e o teste Breusch-Godfrey corrobora a hipótese nula de ausência de autocorrelação nos resíduos ($LM_{(12)}=14,0$ e valor-p 0,3). A Figura 17 apresenta o gráfico das previsões realizadas pelo modelo *ADL*(12,3,10) dentro da amostra, os valores observados e os resíduos.

Devido à presença de multicolinearidade, apresentada no Apêndice A, para a estimação dos parâmetros, recorreu-se ao modelo *ADL* na forma de Bärdsen. O modelo *ADL* na forma de Bärdsen é dado por

$$\begin{aligned} \Delta piy_t = & \mu + \sigma t + \theta_1 piy_{t-1} + \theta_2 nível_{t-1} + \theta_3 temp_{t-1} + \sum_{i=1}^{r-1} \delta_i \Delta piy_{t-i} + \sum_{i=0}^{s_1-1} \gamma_i \Delta nível_{t-i} + \\ & + \sum_{i=0}^{s_2-1} \eta_i \Delta temp_{t-i} + \varepsilon_t \end{aligned} \quad (42)$$

FIGURA 17 - GRÁFICO DO MODELO ADL NO CONJUNTO DE TREINAMENTO PARA PIY



FONTE: A autora (2016).

Na Tabela 6 encontram-se os coeficientes estimados por mínimos quadrados ordinários do modelo $ADL(12,3,10)$ na forma de Bårdsen ou o ECM irrestrito. O modelo não impõe restrição sobre a constante e inclui o termo tendência, pois estes se apresentaram indispensáveis na especificação do modelo¹⁰. Novamente algumas defasagens poderiam ter sido removidas devido ao fato de não serem estatisticamente significativas, no entanto, todas foram mantidas para efeitos de ajuste do modelo.

TABELA 6 - MODELO ECM IRRESTRITO PARA A VARIÁVEL DEPENDENTE PIY

(continua)

Preditores	Coefficiente	Erro Padrão	Estatística t	Valor-p
μ	0,060029	0,022904	2,620906	0,01
t	0,000020	0,000011	1,818181	0,06
nível _{t-1}	-0,000110	0,000100	-1,100881	0,27
temp _{t-1}	-0,000315	0,000033	-9,456158	0,00
piy _{t-1}	-0,015487	0,002257	-6,863102	0,00
Δ piy _{t-1}	0,180860	0,016751	10,796800	0,00
Δ piy _{t-2}	-0,091012	0,017001	-5,353484	0,00
Δ piy _{t-3}	-0,000145	0,017036	-0,008506	0,99
Δ piy _{t-4}	-0,019203	0,017023	-1,128043	0,26
Δ piy _{t-5}	-0,053761	0,017012	-3,160294	0,00
Δ piy _{t-6}	-0,004176	0,017006	-0,245561	0,81

¹⁰ O termo de tendência, mesmo não significativo estatisticamente, quando retirado alterava negativamente o resultado do teste RESET.

				(conclusão)
$\Delta p_{iy_{t-7}}$	-0,022174	0,016984	-1,305535	0,19
$\Delta p_{iy_{t-8}}$	-0,014674	0,016883	-0,869118	0,38
$\Delta p_{iy_{t-9}}$	-0,024926	0,016531	-1,507822	0,13
$\Delta p_{iy_{t-10}}$	-0,052596	0,016386	-3,209903	0,00
$\Delta p_{iy_{t-11}}$	0,027778	0,015741	1,764607	0,08
$\Delta \text{nível}$	0,001749	0,001628	1,074201	0,28
$\Delta \text{nível}_{t-1}$	-0,004390	0,002014	-2,180143	0,03
$\Delta \text{nível}_{t-2}$	0,005462	0,001627	3,358224	0,00
Δtemp	-0,000327	0,000041	-8,042035	0,00
Δtemp_{t-1}	-0,000598	0,000050	-11,986940	0,00
Δtemp_{t-2}	-0,000285	0,000051	-5,606623	0,00
Δtemp_{t-3}	-0,000072	0,000051	-1,421000	0,16
Δtemp_{t-4}	-0,000153	0,000050	-3,049993	0,00
Δtemp_{t-5}	-0,000011	0,000049	-0,215643	0,83
Δtemp_{t-6}	-0,000121	0,000048	-2,510080	0,01
Δtemp_{t-7}	-0,000069	0,000047	-1,487618	0,14
Δtemp_{t-8}	0,000048	0,000045	1,085066	0,28
Δtemp_{t-9}	-0,000088	0,000044	-1,988362	0,05

FONTE: A autora (2016).

4.3.1 Previsão

Os resultados da previsão dinâmica são comparados para os modelos ECM irrestrito, ARIMA e VAR e as medidas para avaliar o erro de previsão foram o RMSE e o MAPE. A Tabela 7 apresenta as medidas de avaliação dos erros dos modelos ECM irrestrito, ARIMA e VAR para os horizontes de previsão $h=7$ (01/07/2015 a 07/07/2015), $h=14$ (01/07/2015 a 14/07/2015), $h=28$ (01/07/2015 a 28/07/2015) e $h=61$ (01/07/2015 a 30/08/2015).

TABELA 7 - MEDIDAS DE AVALIAÇÃO DOS ERROS.

Previsão h dias a frente	ECM irrestrito		ARIMA(1,0,2)		VAR(4)	
	RMSE	MAPE	RMSE	MAPE	RMSE	MAPE
$h=7$	0,0070	0,3105%	0,0009	0,0455%	0,0077	0,3561%
$h=14$	0,0073	0,3266%	0,0070	0,2416%	0,0072	0,3161%
$h=28$	0,0075	0,3292%	0,0088	0,3616%	0,0103	0,5349%
$h=61$	0,0062	0,2702%	0,0161	0,7247%	0,0214	0,9813%


FONTE: A autora (2016).

Foram construídos os gráficos das previsões de todos os modelos para comparação (Figura 18). O modelo ARIMA apresentou uma previsão praticamente constante, bem distinto das observações reais do sensor do pêndulo invertido. As previsões dos modelos ECM irrestrito e VAR são muito semelhantes até o horizonte

de previsão 21 dias, mas as previsões do modelo ECM irrestrito a partir desse horizonte se aproximam melhor das observações reais do pêndulo invertido. As previsões do modelo ECM irrestrito foram as que acompanharam a tendência das observações reais, e visualmente apresentam comportamento semelhante. Este modelo apresentou medidas de avaliação de erro bem mais satisfatórias quando comparadas às dos outros modelos.


Portanto, para o ECM irrestrito foi construído o intervalo de confiança. A Figura 19 apresenta os limites de estado de atenção para o sensor do pêndulo invertido, as previsões e as observações reais do conjunto de teste. Nota-se que os valores observados não ultrapassam os limites do estado de atenção ($\hat{y}_t \pm 2se$), evidenciando que, para esse horizonte de previsão, as leituras do instrumento continuaram a comportar-se como no passado.

FIGURA 18 - PREVISÕES DOS MODELOS PARA O SENSOR PIY (HORIZONTE H=61 DIAS)



FONTE: A autora (2016).

FIGURA 19 - INTERVALO DE CONFIANÇA PARA AS OBSERVAÇÕES DO SENSOR PIY



FONTE: A autora (2016).

4.4 MODELO PARA A VARIÁVEL DEPENDENTE PDX


O conjunto de treinamento consiste nas observações de 27/10/2005 a 30/09/2015 e o conjunto de teste consiste nas observações de 01/10/2015 a 30/11/2015. Neste modelo adotou-se o número doze como máximo de defasagens da variável dependente (*pdx*) e das variáveis independentes (*nível*, *temp*) e foram avaliados 2028 modelos pelo *software* Eviews 9. Pelo critério AIC o modelo ótimo selecionado foi o *ADL(9, 7, 10)*, onde 9 (nove) é a defasagem da variável dependente *pdx*, 7 (sete) é a defasagem da variável *nível* e, por fim, 10 (dez) é a defasagem da variável *temp*. O modelo é dado pela seguinte equação

$$pdx_t = \mu + \sigma t + \sum_{i=1}^r \alpha_i pdx_{t-i} + \sum_{i=0}^{s_1} \beta_i nível_{t-i} + \sum_{i=0}^{s_2} \phi_i temp_{t-i} + \varepsilon_t \quad (43)$$

Quanto ao diagnóstico do modelo, o teste RESET com estatística $F_{(2,3584)}=2,85$ e valor-p de 0,07 não rejeita a hipótese nula de correta especificação do modelo e o teste Breusch-Godfrey corrobora a hipótese nula de ausência de autocorrelação nos resíduos ($LM_{(3)}=4,31$ e valor-p 0,23). A Figura 20 apresenta o

gráfico das previsões realizadas pelo modelo $ADL(9,7,10)$ dentro da amostra, os valores observados e os resíduos.

FIGURA 20 - GRÁFICO DO MODELO ADL NO CONJUNTO DE TREINAMENTO PARA PDX



FONTE: A autora (2016).

Para a estimação dos parâmetros, recorreu-se ao modelo ADL na forma de Bärdsen, que atenua problemas de multicolinearidade frequentes no modelo ADL original conforme apresentado no Apêndice A. O modelo ADL na forma de Bärdsen é dado por

$$\Delta pdx_t = \mu + \sigma t + \theta_1 pdx_{t-1} + \theta_2 nível_{t-1} + \theta_3 temp_{t-1} + \sum_{i=1}^{r-1} \delta_i \Delta pdx_{t-i} + \sum_{i=0}^{s_1-1} \gamma_i \Delta nível_{t-i} + \sum_{i=0}^{s_2-1} \eta_i \Delta temp_{t-i} + \varepsilon_t \quad (44)$$

Na Tabela 8 encontram-se os coeficientes estimados por mínimos quadrados ordinários do modelo $ADL(9,7,10)$ na forma de Bärdsen ou o ECM irrestrito. O modelo não inclui restrição sobre a constante e inclui o termo de tendência, pois estes e algumas defasagens foram relevantes no modelo para efeitos de ajuste.

TABELA 8 - MODELO ECM IRRESTRITO PARA A VARIÁVEL DEPENDENTE PDX

Preditores	Coeficiente	Erro Padrão	Estatística t	Valor-p
μ	-0,371555	0,258323	-1,438335	0,15
t	0,000003	0,000001	2,405695	0,02
nível _{t-1}	0,003476	0,001194	2,912360	0,00
temp _{t-1}	-0,007285	0,000506	-14,401700	0,00
pdx _{t-1}	-0,015081	0,001315	-11,466450	0,00
Δ pdx _{t-1}	-0,072053	0,016463	-4,376675	0,00
Δ pdx _{t-2}	0,034795	0,016493	2,109655	0,04
Δ pdx _{t-3}	-0,025248	0,016487	-1,531413	0,13
Δ pdx _{t-4}	-0,025723	0,016469	-1,561888	0,12
Δ pdx _{t-5}	0,002895	0,016459	0,175869	0,86
Δ pdx _{t-6}	-0,007493	0,016339	-0,458623	0,65
Δ pdx _{t-7}	0,002074	0,016129	0,128575	0,90
Δ pdx _{t-8}	0,072059	0,016087	4,479296	0,00
Δ nível	0,084641	0,018838	4,493101	0,00
Δ nível _{t-1}	0,082564	0,022876	3,609278	0,00
Δ nível _{t-2}	0,032510	0,022933	1,417588	0,16
Δ nível _{t-3}	-0,013155	0,022960	-0,572936	0,57
Δ nível _{t-4}	0,065946	0,022966	2,871498	0,00
Δ nível _{t-5}	-0,003798	0,022949	-0,165516	0,87
Δ nível _{t-6}	-0,030908	0,019207	-1,609194	0,11
Δ temp	0,000099	0,000459	0,214864	0,83
Δ temp _{t-1}	-0,002435	0,000662	-3,675143	0,00
Δ temp _{t-2}	-0,003151	0,000654	-4,820591	0,00
Δ temp _{t-3}	-0,002053	0,000641	-3,203044	0,00
Δ temp _{t-4}	-0,003092	0,000626	-4,936055	0,00
Δ temp _{t-5}	-0,002139	0,000604	-3,538766	0,00
Δ temp _{t-6}	-0,002252	0,000577	-3,904284	0,00
Δ temp _{t-7}	-0,001875	0,000544	-3,448465	0,00
Δ temp _{t-8}	-0,001459	0,000491	-2,971230	0,00
Δ temp _{t-9}	-0,000782	0,000465	-1,681072	0,09

FONTE: A autora (2016).

A abordagem *Bounds Testing* é então iniciada. Estimado o modelo ECM irrestrito (Tabela 8), passa-se à fase de verificação da existência de cointegração, ou seja, se existe ou não um relacionamento a longo prazo entre as temperaturas e nível do reservatório com o deslocamento na direção do fluxo mensurado pelo pêndulo direto. Para isso, efetua-se o teste F de significância conjunta dos coeficientes referentes aos regressores defasados um período, nomeadamente pdx_{t-1} , $nível_{t-1}$ e $temp_{t-1}$. A hipótese de nulidade conjunta dos coeficientes significa que não existe relação de equilíbrio a longo prazo.

O valor da estatística F foi de 72,1 com valor-p de 0,00. Recorrendo aos valores críticos propostos por Pesaran, Shin e Smith (2001), para um modelo que não faz restrição sobre a constante e inclui termo de tendência, o valor da estatística F excede o limite superior mesmo ao nível de 1% de significância que tem como limites 6,34 e 7,52. Portanto, há evidências de relação de equilíbrio de longo prazo ao rejeitar fortemente a hipótese nula.

É importante testar também a nulidade do coeficiente de pdx_{t-1} (o teste ECM) contra a alternativa de que o mesmo é menor que zero, que corresponde a condição necessária de estabilidade do modelo. O valor da estatística F é de 131,5 com valor-p de 0,00, ou seja, rejeita-se fortemente a hipótese nula, reforçando o resultado anterior de existência de relação de equilíbrio de longo prazo.

A relação estática é dada por

$$pdx_t = \mu + \sigma t + \alpha_1 \text{nível} + \alpha_2 \text{temp}_t + v_t \quad (45)$$

e as estimativas são dadas na Tabela 9. Como interessa o modelo dinâmico de curto prazo para fins de previsão, passa-se a estimação do modelo ECM restrito dado por

$$\Delta pdx_t = \sum_{i=1}^{r-1} \delta_i \Delta pdx_{t-i} + \sum_{i=0}^{s_1-1} \gamma_i \Delta \text{nível}_{t-i} + \sum_{i=0}^{s_2-1} \eta_i \Delta \text{temp}_{t-i} + \lambda(v_{t-1}) + \varepsilon_t \quad (46)$$

A equação (46) ou o ECM restrito indica a variação de curto prazo de deslocamentos na direção do fluxo (radiais) influenciados pela variação do nível do reservatório e de temperatura ambiente. Por exemplo, se o deslocamento tangencial se afasta do equilíbrio de longo prazo, o desequilíbrio de curto prazo vai ser restaurado para o equilíbrio. A Tabela 9 apresenta os coeficientes do ECM restrito obtidos pelo método de dois passos de Engle-Granger.

TABELA 9 - MODELO ECM RESTRITO PARA A VARIÁVEL DEPENDENTE PDX

(continua)

Coeficientes de longo prazo				
Preditores	Coeficiente	Erro Padrão	Estatística t	Valor-p
μ	-73,117950	3,897630	-18,759590	0,00
t	0,000280	0,000018	15,541060	0,00
nível	0,413747	0,017580	23,535450	0,00
temp	-0,117884	0,003848	-30,631850	0,00

(conclusão)

Coeficientes do ECM restrito				
Preditores	Coeficiente	Erro Padrão	Estatística t	Valor-p
v_{t-1}	-0,005347	0,001139	-4,693969	0,00
Δpdx_{t-1}	-0,024404	0,016521	-1,477203	0,14
Δpdx_{t-2}	0,087761	0,016464	5,330431	0,00
Δpdx_{t-3}	0,025320	0,016498	1,534771	0,12
Δpdx_{t-4}	0,027267	0,016438	1,658799	0,10
Δpdx_{t-5}	0,057421	0,016400	3,501332	0,00
Δpdx_{t-6}	0,045793	0,016294	2,810424	0,00
Δpdx_{t-7}	0,057714	0,016026	3,601256	0,00
Δpdx_{t-8}	0,126347	0,016009	7,892474	0,00
$\Delta \text{nível}$	0,094860	0,019212	4,937591	0,00
$\Delta \text{nível}_{t-1}$	0,073918	0,023446	3,152620	0,00
$\Delta \text{nível}_{t-2}$	0,023778	0,023514	1,011219	0,31
$\Delta \text{nível}_{t-3}$	-0,021657	0,023545	-0,919838	0,36
$\Delta \text{nível}_{t-4}$	0,058277	0,023554	2,474224	0,01
$\Delta \text{nível}_{t-5}$	-0,010326	0,023541	-0,438633	0,66
$\Delta \text{nível}_{t-6}$	-0,054303	0,019568	-2,775068	0,01
Δtemp	0,000523	0,000470	1,112478	0,27
Δtemp_{t-1}	-0,008627	0,000497	-17,370121	0,00
Δtemp_{t-2}	-0,008633	0,000530	-16,284757	0,00
Δtemp_{t-3}	-0,006788	0,000553	-12,269845	0,00
Δtemp_{t-4}	-0,007171	0,000565	-12,695253	0,00
Δtemp_{t-5}	-0,005443	0,000568	-9,580049	0,00
Δtemp_{t-6}	-0,004832	0,000559	-8,647649	0,00
Δtemp_{t-7}	-0,003764	0,000539	-6,985397	0,00
Δtemp_{t-8}	-0,002531	0,000496	-5,099549	0,00
Δtemp_{t-9}	-0,001237	0,000475	-2,602123	0,01

FONTE: Os autores (2016).

Os preditores tem capacidade significativa para explicar Δpdx_t , uma vez que a estatística F no valor de 51,7 (valor-p de 0,00), rejeita a hipótese nula de não significância conjunta das estimativas. Assim como no ECM irrestrito, algumas estimativas apresentaram valor-p inferior a 0,05, no entanto foram mantidas para melhorar o nível de especificação do modelo. O erro padrão da regressão foi de 0,063, o coeficiente de determinação foi de 0,27 e a estatística Durbin-Watson foi de 2,02.

A estimativa do coeficiente de ajustamento de curto prazo para o equilíbrio é estatisticamente significativa e apresenta sinal negativo esperado ($\lambda = -0,005347$). Isto é importante, pois apoia a aceitação de cointegração estabelecida anteriormente. Por fim, em relação ao diagnóstico do modelo, o teste Breusch-Godfrey corrobora a hipótese nula de ausência de autocorrelação nos resíduos ($LM_{(4)}=9,39$ e valor-p 0,08).

4.4.1 Previsão

No modelo para a variável *pdx* também será realizada a previsão fora da amostra, na abordagem dinâmica. Os resultados das medidas de avaliação do erro (RMSE e MAPE) serão comparados para os modelos ECM irrestrito, ECM restrito, ARIMA e VAR. A Tabela 10 apresenta essas medidas para os horizontes de previsão $h=7$ (01/10/2015 a 07/10/2015), $h=14$ (01/10/2015 a 14/10/2015), $h=28$ (01/10/2015 a 28/10/2015) e $h=61$ (01/10/2015 a 30/11/2015).

TABELA 10 - MEDIDAS DE AVALIAÇÃO DOS ERROS.

Previsão h dias a frente	ECM irrestrito		ECM restrito		ARIMA(3,1,2)		VAR	
	RMSE	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE	MAPE
h=7	0,0261	0,1652%	0,0585	0,3104%	0,0205	0,1011%	0,0925	0,5244%
h=14	0,0555	0,2652%	0,0971	0,4597%	0,0595	0,2783%	0,1551	0,8735%
h=28	0,0661	0,3282%	0,2123	1,1081%	0,0928	0,4105%	0,3718	2,0366%
h=61	0,0876	0,4522%	0,4354	2,3801%	0,0848	0,3894%	0,5325	3,1852%

FONTE: A autora (2016).

Foram construídos os gráficos das previsões de todos os modelos para comparação (Figura 21). O modelo ARIMA apresentou uma previsão praticamente constante, as previsões do modelo VAR e ECM restrito tem comportamento bem distinto das observações reais do pêndulo invertido, e, o modelo ECM irrestrito se aproxima bem das observações reais do pêndulo invertido. Mesmo que o modelo ARIMA tenha apresentado menores RMSE e MAPE, foram as previsões do modelo ECM irrestrito que acompanharam a tendência das observações reais.

Portanto, para o ECM irrestrito foi construído o intervalo de confiança. A Figura 22 apresenta os limites de estado de atenção para o sensor do pêndulo direto, as previsões e as observações reais do conjunto de teste. Nota-se que os valores observados não ultrapassam os limites do estado de atenção ($\hat{y}_t \pm 2se$), evidenciando que, para esse horizonte de previsão, as leituras do instrumento continuaram a comportar-se como no passado.

FIGURA 21 - PREVISÕES DOS MODELOS PARA O SENSOR PDX (HORIZONTE H=61 DIAS)






FIGURA 22 - INTERVALO DE CONFIANÇA PARA AS OBSERVAÇÕES DO SENSOR PDX



4.5 MODELO PARA A VARIÁVEL DEPENDENTE PDY

Para este sensor do pêndulo direto aplica-se metodologia diferenciada, pois nota-se um comportamento distinto a partir de agosto de 2011 (Figura 23). Mais especificamente, do dia 17/10/2011 a 11/01/2012 e do dia 26/02/2012 a 21/03/2012, as leituras do sensor não foram armazenadas, o que pode significar uma eventual falha no sensor ou no sistema de aquisição de dados.

FIGURA 23 - SÉRIE HISTÓRICA DO SENSOR DO PÊNDULO DIRETO (PDY)



FONTE: A autora (2016).

Outros períodos de tempo não apresentaram dados até o término da amostra no dia 30/11/2015, mas com menores quantidades de dias ausentes. Nota-se também que muitos valores atípicos de deslocamentos foram verificados como nas datas 26/09/2012 (-1,08 mm) e 10/01/2014 (-2,55 mm). Houve uma diferença incomum entre os valores de observações próximas como em 08/01/2014 (-2,27 mm), 09/01/2014 (dado ausente) e 10/01/2014 (-2,55 mm). Percebe-se também que o comportamento da série no ano de 2015 é diferente, com uma amplitude de deslocamento muito inferior à amplitude dos demais anos (ver Figura 23).

Assim, para este sensor pdy, a modelagem foi realizada com um objetivo distinto. Será que o modelo é capaz de reconhecer previamente o período incomum? Será que o modelo utilizando os dados até julho de 2011 poderia alertar sobre uma possível mudança de comportamento nas leituras do sensor? É o que se espera. Ou

seja, após agosto de 2011, esperam-se observações fora do intervalo de confiança. As previsões serão realizadas até 16/10/2011 (antes do longo período de dados ausentes).

O conjunto de treinamento e o conjunto para teste seguem então a seguinte configuração: de 27/10/2005 a 31/07/2011 para o conjunto de treinamento e 01/08/2011 a 16/10/2011 para o conjunto de teste. As séries neste novo período de análise têm ordens de integração diferentes (Tabela 2). A variável *pdv* é $I(1)$ e a variável *temp* é $I(0)$. Nesta modelagem a variável *nível* foi considerada *a priori*, mas não era significativa para fins de previsão, então optou-se por considerar apenas a variável *temp* como variável independente.

Antes de verificar a cointegração determina-se o número de defasagens do modelo *ADL*. Adota-se o número doze como máximo de defasagens da variável dependente (*pdv*) e também para a variável independente (*temp*).

Foram avaliados 2092 modelos pelo *software* Eviews 9. O modelo ótimo selecionado foi o *ADL*(3, 9) pelo critério AIC, onde 3 (três) é a defasagem da variável dependente *pdv* e 9 (nove) é a defasagem da variável *temp*. O modelo é dado pela seguinte equação

$$pdv_t = \mu + \sum_{i=1}^r \alpha_i pdv_{t-i} + \sum_{i=0}^{s_1} \beta_i temp_{t-i} + \varepsilon_t \quad (47)$$

Quanto ao diagnóstico do modelo, o teste RESET com estatística $F_{(2,2079)}=2,7$ e valor-p de 0,06 não rejeita a hipótese nula de correta especificação do modelo e o teste Breusch-Godfrey corrobora a hipótese nula de ausência de autocorrelação nos resíduos ($LM_{(5)}=9,69$ e valor-p 0,08). A Figura 24 apresenta o gráfico das previsões realizadas pelo modelo *ADL*(3,9) dentro da amostra, os valores observados e os resíduos.


O ECM irrestrito (*ADL* na forma de Bärdsen) é dado por

$$\Delta pdv_t = \mu + \theta_1 pdv_{t-1} + \theta_2 temp_{t-1} + \sum_{i=1}^{r-1} \delta_i \Delta pdv_{t-i} + \sum_{i=0}^{s_1-1} \gamma_i \Delta temp_{t-i} + \varepsilon_t \quad (48)$$

Na Tabela 11 encontram-se os coeficientes estimados por mínimos quadrados ordinários do modelo *ADL*(3,9) na forma de Bärdsen ou o ECM irrestrito.

O modelo $ADL(3,9)$ inclui constante e não inclui termo de tendência, pois este último é estatisticamente não significativo.

FIGURA 24 - GRÁFICO DO MODELO ADL NO CONJUNTO DE TREINAMENTO PARA PDY



FONTE: A autora (2016).

TABELA 11 - MODELO ECM IRRESTRITO PARA A VARIÁVEL DEPENDENTE PDY

Preditores	Coeficiente	Erro Padrão	Estatística t	Valor-p
μ	-0,008483	0,004243	-1,999354	0,05
$temp_{t-1}$	-0,000303	0,000072	-4,217990	0,00
$pd_{y_{t-1}}$	-0,007270	0,001980	-3,671768	0,00
$\Delta pd_{y_{t-1}}$	0,215277	0,021856	9,849920	0,00
$\Delta pd_{y_{t-2}}$	-0,055618	0,021730	-2,559528	0,01
$\Delta temp$	-0,000685	0,000128	-5,340518	0,00
$\Delta temp_{t-1}$	0,001544	0,000138	11,212230	0,00
$\Delta temp_{t-2}$	0,001379	0,000144	9,569064	0,00
$\Delta temp_{t-3}$	0,000894	0,000145	6,163786	0,00
$\Delta temp_{t-4}$	0,001022	0,000144	7,109571	0,00
$\Delta temp_{t-5}$	0,000507	0,000139	3,640147	0,00
$\Delta temp_{t-6}$	0,000472	0,000136	3,474987	0,00
$\Delta temp_{t-7}$	0,000672	0,000129	5,229578	0,00
$\Delta temp_{t-8}$	0,000210	0,000129	1,622946	0,10

FONTE: A autora (2016).

Agora sim, verifica-se a existência ou não de cointegração, ou seja, se existe ou não um relacionamento a longo prazo entre as temperaturas do ambiente com o

deslocamento na direção normal ao fluxo mensurado pelo pêndulo direto. Para isso, efetua-se o teste F de significância conjunta dos coeficientes referentes aos regressores $pd y_{t-1}$ e $temp_{t-1}$. O valor da estatística F foi de 13,81 com valor-p de 0,00. Recorrendo aos valores críticos propostos por Pesaran, Shin e Smith (2001), para um modelo que inclui constante, o valor da estatística F excede o limite superior mesmo ao nível de 1% de significância que tem como limites 6,84 e 7,84. Portanto, há evidências de relação de equilíbrio de longo prazo ao rejeitar fortemente a hipótese nula.

É importante testar também a nulidade do coeficiente de $pd y_{t-1}$ (o teste ECM) contra a alternativa de que o mesmo é menor que zero, que corresponde a condição necessária de estabilidade do modelo. O valor da estatística F é de 13,5 com valor-p de 0,00, ou seja, rejeita-se a hipótese nula reforçando o resultado anterior de existência de relação de equilíbrio de longo prazo.

Para estimar o ECM restrito é necessário estimar a relação estática, ou seja, estimar os coeficientes da relação de equilíbrio de longo prazo. Neste modelo, os parâmetros são estimados consistentemente por mínimos quadrados ordinários, entretanto, os procedimentos usuais de inferência não serão necessariamente válidos, pois existe variável não estacionária. A relação estática incluindo o termo constante é dada por

$$pd y_t = \mu + \alpha_1 temp_t + v_t \quad (49)$$

e as estimativas são dadas na Tabela 12. Como interessa o modelo dinâmico de curto prazo para fins de previsão, passa-se a estimação do modelo ECM restrito dado pela equação

$$\Delta pd y_t = \sum_{i=1}^{r-1} \delta_i \Delta pd y_{t-i} + \sum_{i=0}^{s_1-1} \gamma_i \Delta temp_{t-i} + \lambda(v_{t-1}) + \varepsilon_t \quad (50)$$

A equação (50) ou o ECM restrito indica a variação de curto prazo de deslocamentos na direção normal ao fluxo (tangenciais) influenciados pela variação da temperatura ambiente. Por exemplo, se o deslocamento tangencial se afasta do equilíbrio de longo prazo, o desequilíbrio de curto prazo vai ser restaurado para o

equilíbrio. A Tabela 12 apresenta o ECM restrito obtido pelo método de dois passos de Engle-Granger.

TABELA 12 - MODELO ECM RESTRITO PARA A VARIÁVEL DEPENDENTE PDY

Coeficientes de longo prazo				
Preditores	Coeficiente	Erro Padrão	Estatística t	Valor-p
μ	-1,986401	0,016071	-123,6015	0,00
temp	-0,004082	0,000710	-5,745375	0,00
Coeficientes do ECM restrito				
Preditores	Coeficiente	Erro Padrão	Estatística t	Valor-p
v_{t-1}	-0,007033	0,001976	-3,559107	0,00
Δpdy_{t-1}	0,221917	0,021855	10,154232	0,00
Δpdy_{t-2}	-0,050485	0,021755	-2,320597	0,02
$\Delta temp$	-0,000620	0,000128	-4,858657	0,00
$\Delta temp_{t-1}$	0,001346	0,000128	10,508366	0,00
$\Delta temp_{t-2}$	0,001195	0,000136	8,765290	0,00
$\Delta temp_{t-3}$	0,000718	0,000138	5,203032	0,00
$\Delta temp_{t-4}$	0,000871	0,000139	6,281124	0,00
$\Delta temp_{t-5}$	0,000382	0,000136	2,812027	0,00
$\Delta temp_{t-6}$	0,000370	0,000134	2,765015	0,01
$\Delta temp_{t-7}$	0,000598	0,000127	4,688248	0,00
$\Delta temp_{t-8}$	0,000139	0,000128	1,082628	0,28

FONTE: A autora (2016).

Os preditores tem capacidade significativa para explicar Δpdy_t , uma vez que a estatística F no valor de 37,68 (valor-p de 0,00), rejeita a hipótese nula de não significância conjunta das estimativas. Apenas uma estimativa se apresentou estatisticamente não significativa (coeficiente de $\Delta temp_{t-8}$) com valor-p de 0,28, no entanto, foi mantida para melhorar o nível de especificação do modelo. O erro padrão da regressão foi de 0,01, o coeficiente de determinação foi de 0,17 e a estatística Durbin-Watson foi de 2,00.

A estimativa do coeficiente de ajustamento de curto prazo para o equilíbrio é estatisticamente significativa e apresenta sinal negativo esperado ($\lambda = -0,007$). Isto é importante, pois apoia a aceitação de cointegração estabelecida anteriormente. Por fim, em relação ao diagnóstico do modelo, o teste Breusch-Godfrey corrobora a hipótese nula de ausência de autocorrelação nos resíduos ($LM_{(5)}=8,5$ e valor-p 0,13).

4.5.1 Previsão

No modelo para a variável *pdv* também será realizada a previsão fora da amostra, na abordagem dinâmica. Os resultados da previsão dinâmica serão comparados para os modelos ECM irrestrito, ECM restrito, ARIMA e VAR.

As medidas para avaliar o erro de previsão foram o RMSE e o MAPE. A Tabela 13 apresenta as medidas de avaliação dos erros dos modelos ECM irrestrito, ECM restrito, ARIMA e VAR para os horizontes de previsão $h=7$ (01/08/2011 a 07/08/2011), $h=14$ (01/08/2011 a 14/08/2011), $h=28$ (01/08/2011 a 28/08/2011), $h=61$ (01/08/2011 a 30/09/2011) e o horizonte de previsão que antecede o período de dados ausentes $h=77$ (01/08/2011 a 16/10/2011).

TABELA 13 - MEDIDAS DE AVALIAÇÃO DOS ERROS.

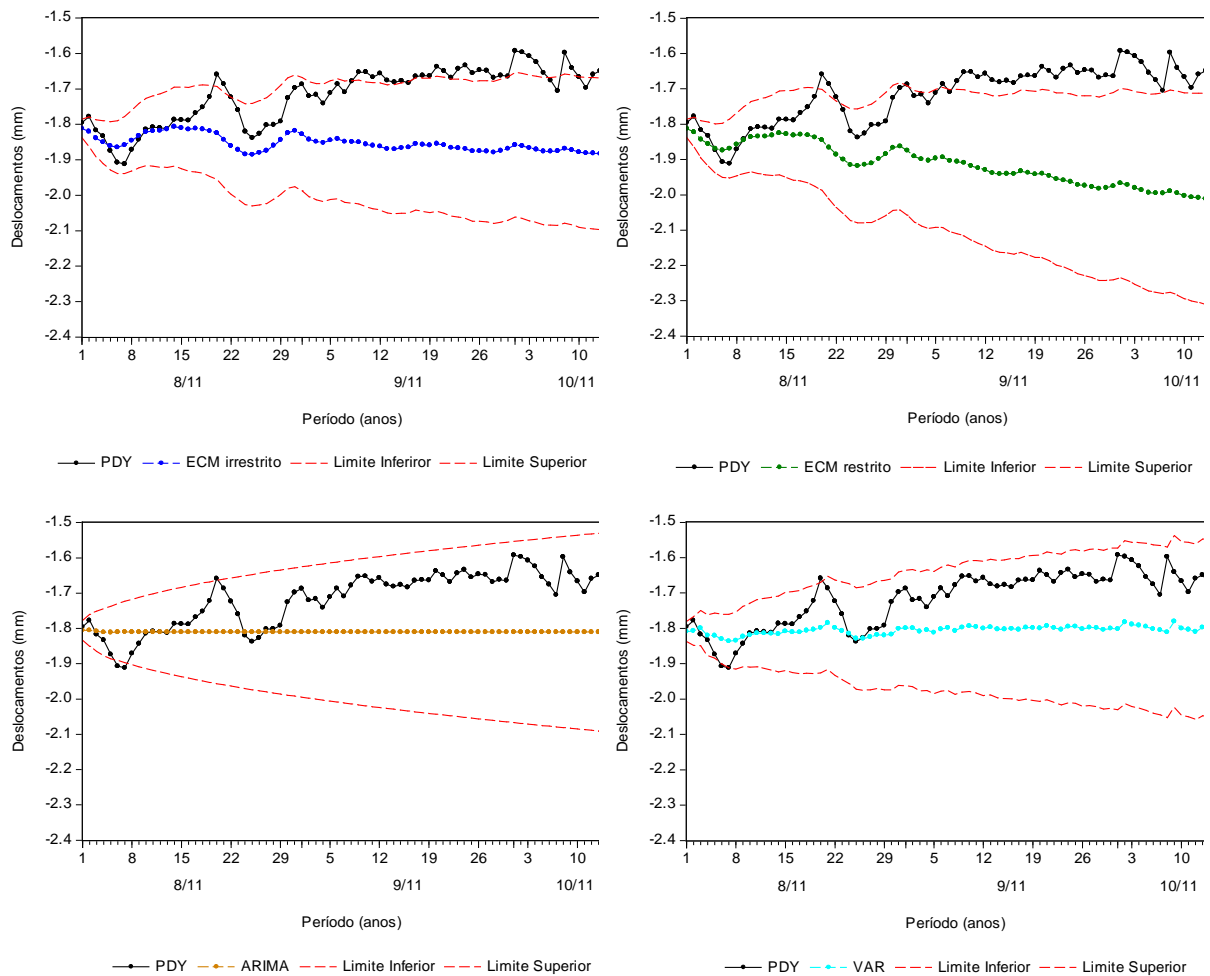
Previsão h dias a frente	ECM irrestrito		ECM restrito		ARIMA(4,1,2)		VAR	
	RMSE	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE	MAPE
$h=7$	0,0380	1,7843%	0,0358	1,6752%	0,0618	2,6850%	0,0505	2,3149%
$h=14$	0,0286	1,2179%	0,0302	1,4178%	0,0479	1,8297%	0,0383	1,5604%
$h=28$	0,0679	2,9018%	0,0838	3,7260%	0,0584	2,3989%	0,0502	2,1004%
$h=61$	0,1429	7,1218%	0,1985	9,8434%	0,1078	5,3861%	0,0992	4,9595%
$h=77$	0,1651	8,5436%	0,2387	12,2394%	0,1224	6,3362%	0,1130	5,8458%

FONTE: A autora (2016).

Calculam-se os limites de confiança para os quatro modelos, pois o objetivo é verificar quais modelos identificam o comportamento anormal da série temporal, previamente (Figura 25). Para este sensor *pdv*, após agosto de 2011, esperam-se observações fora do intervalo de confiança. As previsões foram realizadas até 16/10/2011, data que antecede o longo período de dados ausentes observado na série original, observe na Figura 23 o período de dados ausentes a partir do dia 17/10/2011.

Nota-se que as menores medidas de avaliação de erro são para o modelo VAR (Tabela 13), no entanto, os limites de confiança deste modelo não detectaram uma alteração no comportamento da série temporal.

FIGURA 25 - INTERVALOS DE CONFIANÇA PARA AS PREVISÕES DOS QUATRO MODELOS




FONTE: A autora (2016).

Ambos os modelos, ECM irrestrito e ECM restrito detectaram as alterações no sensor *pdy*, enquanto que os modelos ARIMA e VAR não. Como os valores observados pelo sensor *pdy* ultrapassaram o limite superior ($\hat{y}_t + 2se$), tem-se um estado de atenção. Sendo o modelo ECM irrestrito escolhido, pela sua simplicidade em relação ao modelo ECM restrito, nota-se que os valores observados não ultrapassam os limites ($\hat{y}_t \pm 3se$), o que indicaria um estado de alerta. A Figura 26 apresenta as observações do sensor *pdy*, as previsões do modelo ECM irrestrito e seus limites de estado de atenção e limites de estado de alerta.

Diante de um estado de atenção que se manteve, investiga-se a possível causa. Sobre a ausência de leituras, deve-se esclarecer que esse período ausente, após 16/10/2011, trata-se simplesmente de falhas dos sensores.

FIGURA 26 - LIMITES DE ATENÇÃO E DE ALERTA PARA O SENSOR PDY



FONTE: A autora (2016).

Quanto ao comportamento da série após agosto de 2012 (período de ausência de leituras e leituras atípicas), existem duas observações independentes entre si:


- 1) Desde 2013, observa-se um tipo de *offset* entre leituras manuais e automatizadas, ou seja, um afastamento entre as mesmas (Figura 27). Isto pode significar algo relativo à calibração dos instrumentos ou eventualmente ser reflexo de equipe nova de técnicos que fazem as leituras manuais. A leitura manual pode sofrer interferências de acordo com a acuidade visual e da atenção/cuidado de cada profissional, embora isso sempre seja tratado com muita responsabilidade. Portanto, entende-se que o comportamento atípico deve ser atribuído à calibração. Ressalta-se também que este *offset* nas leituras do sensor pdy é da ordem de 0,2 a 0,3 mm e que as variações entre verão e inverno (máximos e mínimos) historicamente foram de 0,5 mm, exceto pelo inverno 2012 (rigoroso) onde mediu-se aproximadamente 1 mm de

variação. Tais oscilações de valores que foram evidenciadas pelos modelos estatísticos, neste caso, não foram devido a problemas estruturais.

- 2) Em 2015, a mudança de comportamento da série pode ser devida à ausência do pico típico de pós-inverno (setembro/outubro), tanto em observações manuais quanto nas automatizadas. Isto porque o inverno foi diferente neste ano: poucos dias frios e/ou temperatura média não tão baixa. Quando ocorrem estas situações a estrutura sente os efeitos do inverno moderadamente. No gráfico de temperaturas pode-se observar que o inverno foi mais ameno em 2015 (Figura 28).


Portanto, o modelo ECM irrestrito foi capaz de identificar previamente que as leituras do sensor *pd*y indicavam um estado de atenção, mas não um estado de alerta, o que foi confirmado pelo setor de engenharia, quando nenhuma situação de risco aconteceu nesse período.

FIGURA 27 - OFFSET ENTRE AS LEITURAS MANUAIS E AUTOMATIZADAS



FONTE: CEASB – ITAIPU (2016).

FIGURA 28 - TEMPERATURA AMBIENTE (DESTAQUE NOS PICOS DE INVERNOS DE CADA ANO)



FONTE: CEASB – ITAIPU (2016).

5 CONCLUSÃO

A metodologia proposta neste trabalho vem contribuir com novos modelos de previsão para os deslocamentos horizontais em barragens de concreto, sob efeitos de variação de temperatura ambiente e variação do nível do reservatório. Os modelos de previsão propostos auxiliam no monitoramento de um bloco da barragem com a definição de novos limites para as leituras dos pêndulos direto e invertido.

A presença da multicolinearidade entre as variáveis, a autocorrelação e a presença de séries não estacionárias foram determinantes para a escolha do modelo ADL na forma de Bårdsen e a abordagem *Bounds Testing*. Na literatura, muitas vezes, estas características dos dados de monitoramento de barragem são ignoradas.

O pré-processamento dos dados foi uma das ações que antecederam esta modelagem. Os dados apresentavam erros de leituras, valores ausentes e *outliers*, que foram analisados individualmente. O pré-processamento foi fundamental para a estimação dos parâmetros e permitiu que os testes de diagnósticos dos modelos pudessem ser realizados.

Comparando as previsões dos modelos, a previsão ARIMA apresentou comportamento praticamente constante, bem distinto das observações reais dos sensores dos pêndulos. Quanto ao último sensor, cujo objetivo era distinto dos demais sensores, o modelo ARIMA não detectou as alterações nas leituras do sensor *pd_y*, apresentando observações dentro do intervalo de confiança.

O modelo VAR gerou previsões que são muito distintas das observações reais dos deslocamentos. E quanto ao último sensor, o modelo VAR não detectou o comportamento anômalo das leituras.

As previsões do modelo ECM restrito para os sensores *pix*, *pd_x* e *pi_y* não foram satisfatórias, apresentando medidas de avaliação de erros maiores que as do modelo ECM irrestrito. Uma justificativa para isso seria que na relação de longo prazo, os parâmetros são estimados (mínimos quadrados ordinários) no modelo estático. O modelo para o sensor *pd_y* foi capaz de alertar sobre uma mudança de comportamento das observações com relação ao período considerado estável.

As previsões do modelo ECM irrestrito foram as que acompanharam melhor a tendência das observações reais, o modelo apresentou medidas de avaliação de erro menores e no caso do último sensor *pd_y*, o modelo identificou o comportamento

anômalo das observações, quando as observações reais são superiores ao limite superior do intervalo de confiança.

Portanto, para o ECM irrestrito foi construído o intervalo de confiança para todos os sensores dos pêndulos, estabelecendo novos limites para as observações dos pêndulos com um horizonte de 2 meses. No caso dos sensores *pix*, *piy* e *pdx* ficou evidente que, para esse horizonte de previsão, as leituras dos instrumentos continuaram a comportar-se como no passado. E no caso do sensor *pd_y*, os dados da série completa não poderiam ser utilizados como treinamento, pois havia uma mudança de comportamento a partir de agosto de 2011 que influenciaria o ajuste e tornaria a previsão enganosa.

Em suma, o modelo ECM irrestrito ou ADL na forma de Bårdsen teve um melhor desempenho nesta aplicação. Este modelo, embora ainda não utilizado em dados de monitoramento de barragens, atende as características particulares dos mesmos como multicolinearidade, autocorrelação e séries não estacionárias. A estimação dos parâmetros se dá por meio de mínimos quadrados ordinários e realizada de uma só vez, de forma simples, motivo pelo qual o modelo ADL na forma de Bårdsen também é denominado de método em um só passo.

A previsão dos deslocamentos e os intervalos de confiança proporcionam uma contribuição aos técnicos e engenheiros na tomada de decisão no que diz respeito ao monitoramento desse bloco. Mas é importante ressaltar que a avaliação de engenheiros e técnicos é indispensável para utilização de qualquer modelo de previsão de dados de monitoramento de barragens, pois se uma observação real não está entre os limites do intervalo de confiança, isso pode não representar situação de risco.

5.1 SUGESTÕES PARA TRABALHOS FUTUROS

Os resultados encontrados neste trabalho apontam para a utilização de modelos dinâmicos na previsão de dados de monitoramento de barragens, propondo a utilização de um modelo que seja robusto às características dos dados, muitas vezes negligenciadas em trabalhos encontrados na literatura. No entanto, outras modelagens podem ser simuladas a fim de capturar a dinâmica dos deslocamentos mensurados pelos pêndulos como:

- avaliar outros métodos para a escolha do número de defasagens do modelo;
- construir os intervalos de confiança por meio de técnicas de reamostragem, como o *bootstrap* e
- considerar as temperaturas do concreto do bloco ao invés da temperatura do ar.

Um trabalho inicial, considerando as temperaturas do concreto, foi apresentado em um artigo. Um modelo ADL foi ajustado onde as temperaturas do concreto mensuradas pelos termômetros de superfície e o nível do reservatório eram as variáveis dependentes. Variáveis *dummies* foram inseridas para capturar os efeitos sazonais e o modelo foi ajustado com dados mensais das leituras manuais observadas no pêndulo direto (GARCIA *et al.*, 2015). Pretende-se melhorar as medidas de avaliação dos erros desse modelo, utilizando as temperaturas dos termômetros de superfície com periodicidade diária, o que requer estudos mais aprofundados sobre técnicas de preenchimento de dados.

Uma outra ideia para trabalhos futuros é estender a modelagem a outros instrumentos como, por exemplo, piezômetros e extensômetros.

Por fim, como trabalhos futuros, pretende-se criar alertas automáticos em caso de desvios da normalidade das leituras, utilizando os modelos dinâmicos, o que seria possível com a integração do banco de dados da instrumentação com um *software* estatístico.

REFERÊNCIAS

- AGÊNCIA NACIONAL DE ÁGUAS - ANA. Manual do Empreendedor – Volume VII - Guia Para Elaboração do Plano de Operação, Manutenção e Instrumentação de Barragens, Brasília, p. 140, 2015. Disponível em: <http://audienciapublica.ana.gov.br/arquivos/Aud_003_2015_Guia_Operacao_Barragens_VII.pdf>. Acesso em: 10 Dezembro 2015.
- AHMADI-NEDUSHAN, B. **Multivariate Statistical Analysis of monitoring data for concrete dams**. Tese de Doutorado do Departamento de Engenharia Civil e Mecânica Aplicada, McGill University. Montreal, p. 211. 2002.
- ARONE, S. G. **Impacto de meios electrónicos de pagamento sobre as notas e moedas em circulação: o caso de Moçambique**. Dissertação Instituto Superior de Economia e Gestão. Lisboa, p. 44. 2014.
- ASTERIOU, D.; HALL, S. G. **Applied Econometrics**. 2ª. ed. London: Palgrave Macmillan, 2011.
- BALBI, D. A. F. **Metodologias para a elaboração de planos de ações emergenciais para inundações induzidas por**. Dissertação (mestrado) – Universidade Federal de Minas Gerais, Departamento de Engenharia Hidráulica e Recursos Hídricos. Belo Horizonte, p. 336. 2008.
- CHAVES NETO, A. **Análise de Séries Temporais**. UFPR. Curitiba, p. 85. 2013.
- CHOUINARD, L.; ROY, V. **Performance of Statistical Models for Dam Monitoring Data**. Joint International Conference on Computing and Decision Making in Civil and Building Engineering. Montreal: [s.n.]. 2006. p. 9.
- COELHO, D. P.; PATIAS, J.; GARAY, V. R. **Sistema de Otimização e Análise de Auscultação da Barragem de Itaipu**. XXX Seminário Nacional de Grandes Barragens. Foz do Iguaçu: [s.n.]. 2015. p. 1-11.
- CORRÊA, J. M. **Método Warimax-Garch Neural para previsão de séries temporais**. Tese - Universidade Federal do Paraná, Setor de Ciências Exatas, Programa de Pós-graduação em Métodos Numéricos em Engenharia. Curitiba, p. 174. 2015.
- DE SORTIS, A.; PAOLIANI, P. Statistical analysis and structural identification in concrete dam monitoring. **Engineering Structures**, v. 1, n. 29, p. 110-120, Janeiro 2007.
- FEDERAL ENERGY REGULATORY COMMISSION - FERC. **Engineering Guidelines for the Evaluation of Hydropower Projects**. Washington. 2008.
- FRIMPONG, J. M.; OTENG-ABAYIE, E. F. Bounds testing approach: an examination of foreign direct investment, trade, and growth relationships. **Munich Personal RePEc Archive - MPRA**, p. 1-19, Agosto 2006.
- FUSARO, T. C. **Estabelecimento Estatístico de Valores de Controle para a Instrumentação de Barragens de Terra: Estudo de Caso das Barragens de Emborcação**

e Piau. Dissertação apresentada ao Mestrado Profissional em Engenharia da Universidade Federal de Ouro Preto - Mestrado Profissional em Engenharia Geotécnica. Ouro Preto, p. 309. 2007.

GARCIA, S. R. P.; CHAVES NETO, A.; ORO, S. R.; NEUMANN JÚNIOR, C. Modeling and Forecasting Displacements in Concrete Dam: An ARDL Bounds Testing Approach. **International Journal of Engineering and Applied Sciences**, v. 7, n. 5, p. 31-39, Dezembro 2015.

GERRARD, W. J.; GODFREY, L. G. Diagnostic Checks for Single-equation Error-correction and Autoregressive Distributed Lag Models. **The Manchester School**, v. 66, n. 2, p. 222-237, 1998.

GUJARATI, D. N. **Basic econometrics**. New York: McGraw Hill, 2004.

HAIR, J. F.; BLACK, W. C.; BABIN, B. J.; ANDERSON, R. E.; TATHAM, R. L. **Análise Multivariada de Dados**. 6ª. ed. São Paulo: Bookman, 2009.

HYNDMAN, R. J.; ATHANASOPOULOS, G. **Forecasting: principles and practice**. [S.l.]: OTexts, 2014.

IHS GLOBAL. **Eviews 9**. [S.l.]: [s.n.], 2015.

ITAIPU BINACIONAL. **Estudos para reavaliação dos valores limites para a instrumentação civil das estruturas da barragem de Itaipu e suas fundações**. Foz do Iguaçu. 1997.

ITAIPU BINACIONAL. **Usina Hidrelétrica de Itaipu: Aspectos de Engenharia**. Foz do Iguaçu: TAB Marketing Editorial, 2009.

ITAIPU BINACIONAL. **USINA HIDRELÉTRICA DE ITAIPU: principais características técnicas**. ITAIPU Binacional. Foz do Iguaçu, p. 31. 2014.

ITAIPU BINACIONAL. Sobre a ITAIPU Binacional. **ITAIPU BINACIONAL A maior geradora de energia limpa e renovável do mundo**, 2015. Disponível em: <<http://www.itaipu.gov.br/energia/barragem>>. Acesso em: 04 Fevereiro 2015.

ITAIPU BINACIONAL. Sobre ITAIPU Binacional. **ITAIPU Binacional A maior geradora de energia limpa e renovável do planeta**, 2016. Disponível em: <<https://www.itaipu.gov.br/energia/geracao>>. Acesso em: 24 abr. 2016.

KRÜGER, C. M. **Análise de Confiabilidade Estrutural Aplicada às Barragens de Concreto**. Tese de Doutorado em Métodos Numéricos em Engenharia da Universidade Federal do Paraná. Curitiba, p. 157. 2008.

KUPERMAN, S. C.; MORETTI, M. R.; CIFU, S.; CELESTINO, T. B.; RE, G.; ZOELLER, K. **Crítérios para fixação de valores limites da instrumentação civil de barragens de concreto e de terra**. XXV Seminário Nacional de Grandes Barragens. Salvador: [s.n.]. 2003. p. 81-96.

LÉGER, P.; LECLERC, M. Hydrostatic, temperature, time-displacement model for concrete dams. **Journal of engineering mechanics**, v. 133, n. 3, p. 267-277, Março 2007.

LI, F.; WANG, Z.; LIU, G. Towards an Error Correction Model for dam monitoring data analysis based on Cointegration Theory. **Structural Safety**, v. 43, p. 12-20, Julho 2013.

LOMBARDI, G.; AMBERG, F.; DARBRE, G. R. Algorithm for the prediction of functional delays in the behaviour of concrete dams. **The international journal on hydropower & dams**, v. 15, n. 3, p. 111-116, 2008.

LOPES, A. S. **Modelos DL e ADL, raízes unitárias e cointegração: uma introdução**. CEMAPRE, ISEG. Lisboa, p. 55. 1999.

MACKINNON, J. G. Numerical distribution functions for unit root and cointegration tests. **Journal of Applied Econometrics**, p. 601-618, 1996.

MATA, J. Interpretation of concrete dam behaviour with artificial neural network and multiple linear regression models. **Engineering Structures**, v. 33, n. 3, p. 903-910, Março 2011.

MATA, J.; DE CASTRO, A. T.; DA COSTA, J. S. Constructing statistical models for arch dam deformation. **Structural Control and Health Monitoring**, v. 21, n. 3, p. 423-437, 2014.

MATHWORKS. **MATLAB versão R2013a**. [S.l.]: [s.n.], 2013.

MATOS, S. F. **Avaliação de instrumentos para auscultação de barragem de concreto. Estudo de caso: Deformímetros e tensômetros para concreto na barragem de Itaipu**. Universidade Federal do Paraná. Curitiba, p. 107. 2002.

NOBLE, N. R. **EViews Tutorials: Forecasting**. Irvine: Quantitative Micro Software, 2011.

ORO, S. R. ; CHAVES NETO, A.; MAFIOLETI, T. R.; GARCIA, S. R. P.; NEUMANN JUNIOR, C. Study of the influence of temperature and level of the reservoir about the displacement of a concrete dam. **International Journal of Applied Mechanics and Engineering**, v. 7, n. 2, p. 526-545, Abril 2016.

OSAKO, C. T. **A manutenção dos drenos nas fundações de barragens: O caso da usina hidrelétrica de Itaipu..** Dissertação - Universidade Federal do Paraná do Programa de Pós-Graduação em Construção Civil - PPGCC. Curitiba. 2002.

PENNA, D. C. R.; ARAGÃO, G. A. S.; FUSARO, T. C. Complementariedade entre o monitoramento e análises de risco na gestão da segurança de barragens. In: **XXX Seminário Nacional de Grandes Barragens**, Foz do Iguaçu, 2015.

PEREIRA, E. N. **Proposta de Modelo Híbrido Composta por Wavelet, ARIMA e Redes Neurais Artificiais de Funções de Bases Radiais para Previsão de Séries Temporais: Uma Aplicação em um Instrumento da Barragem de Itaipu**. Tese - Universidade Federal do Paraná, Setor de Ciências Exatas, Program de Pós-graduação em Métodos Numéricos em Engenharia. Curitiba, p. 127. 2016.

PESARAN, M. H.; SHIN, Y.; SMITH, R. J. Bounds testing approaches to the analysis of level relationships. **Journal of applied econometrics**, v. 16, n. 3, p. 289-326, Fevereiro 2001.

RODRIGUES, S. B.; SILVA, A. C. L.; TEIXEIRA JÚNIOR, L. A.; TEIXEIRA, L. L.; SIQUEIRA, P. H.; FRANCO, E. M. C. Previsão dos deslocamentos relativos no bloco I11 da barragem

da usina hidrelétrica de Itaipu por meio de uma abordagem híbrida ARIMA-SRV. **Espaço Energia**, v. 22, p. 28-37, Abril 2015.

SALAZAR, F.; MORÁN, R.; TOLEDO, M. Á.; OÑATE, E. Data-Based Models for the Prediction of Dam Behaviour: A Review and Some Methodological Considerations. **Archives of Computational Methods in Engineering**, Barcelona, p. 1-21, 2015.

SARÉ, A. R.; LIGOCKI, L. P.; SAYÃO, A.; GERSCOVICH, D. M. S.; PINHEIRO, G. F. Revisão das condições de segurança da barragem de Curuá-Una (PA). In: **XIII Congresso Brasileiro de Mecânica dos Solos e Engenharia Geotécnica**, Curitiba, v. 4, p. 1977-1981, 2006.

SARMENTO, F. J.; MOLINA, O. A. **Barragem Camará - PB: o deplecionamento evitaria a catástrofe?**, 2004. Disponível em: <<http://www.acquatol.com.br/paginas/pub-camara.pdf>>. Acesso em: Setembro 2014.

SERRANO-LOMBILHO, A.; MORALES-TORRES, A.; GARCÍA-KAB, L. Consequence estimation in risk analysis. **Risk Analysis, Dam Safety, Dam Security and Critical Infrastructure Management**, p. 107-112, 2012.

SILVEIRA, J. F. A. **Instrumentação e Comportamento de Fundações de Barragens de Concreto**. São Paulo: Oficina de textos, 2003.

SIMON, A.; ROYER, M.; MAURIS, F.; FABRE, J. **Analysis and interpretation of dam measurements using artificial neural networks**. Proceedings of the 9th ICOLD European club symposium. Venice: [s.n.]. 2013.

TATIN, M.; BRIFFAUT, M.; DUFFOUR, F.; SIMON, A.; FABRE, J. P. Thermal displacements of concrete dams: accounting for water temperature in statistical models. **Engineering Structures**, n. 91, p. 26-29, 2015.

TEIXEIRA, L. L.; SIQUEIRA, P. H.; TEIXEIRA JÚNIOR, L. A. Previsões de vazões mensais no posto 266-lataipu mediante redes neurais com encolhimento wavelet. **Espaço Energia**, v. 22, p. 8-17, Maio 2015.

VASCONCELOS, G. R. L. D. **Plano de implantação e acompanhamento do instrumental de auscultação de estruturas de concreto - obra de Itaipu**. Divisão de controle de concreto - Itaipu Binacional. [S.l.], p. 148. 1978.

VILLWOCK, R. **Técnicas de agrupamento e de hierarquização no contexto KDD – Aplicação a dados temporais de instrumentação geotécnica-estrutural da usina hidrelétrica de Itaipu**. Tese de Doutorado, PPGMNE, Universidade Federal do Paraná. Curitiba, p. 125. 2009.

WOOLDRIDGE, J. M. **Introductory econometrics: a modern approach**. 4ª. ed. Mason: Thomsom, 2006.

XI, G. Y.; YUE, J. P.; ZHOU, B. X.; TANG, P. Application of an artificial immune algorithm on a statistical model of dam displacement. **Computer & Mathematics with Applications**, v. 62, n. 10, p. 3980-3986, Novembro 2011.

YU, H.; Wu, Z.; BAO, T.; ZHANG, L. Multivariate analysis in dam monitoring data with PCA. **Science China Technological Sciences**, v. 53, n. 4, p. 1088-1097, 2010.

APÊNDICES

APÊNDICE A – TABELAS DOS VALORES VIF

APÊNDICE B – SCRIPT DO MATLAB

APÊNDICE C – MODELOS ARIMA E VAR

APÊNDICE D – COMANDOS NO SOFTWARE EVIEWS

APÊNDICE E – MOVIMENTOS NO BLOCO DE CONCRETO À GRAVIDADE

APÊNDICE A – TABELAS DOS VALORES VIF

O fator de inflação da variância (VIF – *Variance Inflation Factor*) quantifica a gravidade da multicolinearidade em uma análise de regressão dos mínimos quadrados ordinários. Essa estatística fornece um índice que mede o quanto a variância de um coeficiente de regressão estimado é maior na presença de colinearidade.

O VIF é calculado para cada x_i (variável independente) dado por $VIF = \frac{1}{1 - R_i^2}$

onde R_i^2 é o coeficiente de determinação da equação de regressão

$x_i = \alpha_1 x_1 + \dots + \alpha_{i-1} x_{i-1} + \alpha_{i+1} x_{i+1} + \dots + \alpha_p x_p$. Avalia-se a magnitude da

multicolinearidade considerando-se o valor de $VIF > 10$ então a multicolinearidade é alta (GUJARATI, 2004). Seguem as tabelas dos valores VIF para os modelos ADL e ECM irrestrito referentes aos quatro sensores. Observa-se em todos os casos que o modelo ECM irrestrito ou ADL na forma de Bårdsen consegue remover a multicolinearidade.

TABELA 14 - VALORES VIF PARA O MODELO DO SENSOR PIX

(continua)

ADL original		ADL na forma de Bårdsen	
Variável	VIF	Variável	VIF
pix _{t-1}	308,1836	nível _{t-1}	1,185874
pix _{t-2}	834,8452	temp _{t-1}	2,632003
pix _{t-3}	878,2307	pix _{t-1}	1,064275
pix _{t-4}	879,2873	Δpix _{t-1}	1,240129
pix _{t-5}	879,048	Δpix _{t-2}	1,358393
pix _{t-6}	875,1619	Δpix _{t-3}	1,366079
pix _{t-7}	872,0259	Δpix _{t-4}	1,37016
pix _{t-8}	871,1408	Δpix _{t-5}	1,37279
pix _{t-9}	873,6217	Δpix _{t-6}	1,346468
pix _{t-10}	874,9689	Δpix _{t-7}	1,347882
pix _{t-11}	826,4611	Δpix _{t-8}	1,343519
pix _{t-12}	300,6619	Δpix _{t-9}	1,341788
nível	439,1655	Δpix _{t-10}	1,33385
nível _{t-1}	1710,168	Δpix _{t-11}	1,20736
nível _{t-2}	1975,917	Δnível	1,976632
nível _{t-3}	1979,078	Δnível _{t-1}	2,915716
nível _{t-4}	1980,229	Δnível _{t-2}	2,948901
nível _{t-5}	1983,222	Δnível _{t-3}	2,953405
nível _{t-6}	1734,641	Δnível _{t-4}	2,950641
nível _{t-6}	446,0315	Δnível _{t-5}	2,945606
temp	4,429205	Δnível _{t-6}	2,013961
temp _{t-1}	8,249366	Δtemp	1,174054
temp _{t-2}	8,480228	Δtemp _{t-1}	1,619567
temp _{t-3}	8,48123	Δtemp _{t-2}	1,645079

			(conclusão)
temp _{t-4}	8,485218	Δ temp _{t-3}	1,641887
temp _{t-5}	8,492167	Δ temp _{t-4}	1,618762
temp _{t-6}	8,495521	Δ temp _{t-5}	1,595034
temp _{t-7}	8,483153	Δ temp _{t-6}	1,55051
temp _{t-8}	8,470668	Δ temp _{t-7}	1,467574
temp _{t-9}	8,467168	Δ temp _{t-8}	1,391849
temp _{t-10}	8,461463	Δ temp _{t-9}	1,303498
temp _{t-11}	8,220915	Δ temp _{t-10}	1,188475
temp _{t-12}	4,450467	Δ temp _{t-11}	1,18111

FONTE: A autora (2016).

TABELA 15 - VALORES VIF PARA O MODELO DO SENSOR PIY

ADL original		ADL na forma de Bärdsen	
Variável	VIF	Variável	VIF
μ	NA	μ	NA
t	1,5	t	1,5
piy _{t-1}	97,2	nível _{t-1}	1,6
piy _{t-2}	228,2	temp _{t-1}	3,0
piy _{t-3}	234,8	piy _{t-1}	1,7
piy _{t-4}	235,6	Δ piy _{t-1}	1,3
piy _{t-5}	235,4	Δ piy _{t-2}	1,3
piy _{t-6}	235,2	Δ piy _{t-3}	1,3
piy _{t-7}	235,2	Δ piy _{t-4}	1,3
piy _{t-8}	234,3	Δ piy _{t-5}	1,3
piy _{t-9}	233,4	Δ piy _{t-6}	1,3
piy _{t-10}	225,5	Δ piy _{t-7}	1,3
piy _{t-11}	213,4	Δ piy _{t-8}	1,3
piy _{t-12}	84,5	Δ piy _{t-9}	1,2
nível	418,3	Δ piy _{t-10}	1,2
nível _{t-1}	1679,7	Δ piy _{t-11}	1,1
nível _{t-2}	1678,9	Δ nível	1,8
nível _{t-2}	417,2	Δ nível _{t-1}	2,8
temp	4,4	Δ nível _{t-2}	1,8
temp _{t-1}	8,4	Δ temp	1,2
temp _{t-2}	8,9	Δ temp _{t-1}	1,8
temp _{t-3}	9,0	Δ temp _{t-2}	1,8
temp _{t-4}	9,0	Δ temp _{t-3}	1,8
temp _{t-5}	9,0	Δ temp _{t-4}	1,8
temp _{t-6}	9,0	Δ temp _{t-5}	1,7
temp _{t-7}	9,0	Δ temp _{t-6}	1,6
temp _{t-8}	9,0	Δ temp _{t-7}	1,5
temp _{t-9}	8,9	Δ temp _{t-8}	1,4
temp _{t-10}	5,2	Δ temp _{t-9}	1,4

FONTE: A autora (2016).

TABELA 16 - VALORES VIF PARA O MODELO DO SENSOR PDX

ADL original		ADL na forma de Bärdsen	
Variável	VIF	Variável	VIF
μ	NA	μ	NA
t	1,430073	t	1,430073
Δ pdx _{t-1}	461,4508	nível _{t-1}	1,747181
Δ pdx _{t-2}	845,8291	temp _{t-1}	5,358495
Δ pdx _{t-3}	848,9245	pdx _{t-1}	2,866893
Δ pdx _{t-4}	850,5898	Δ pdx _{t-1}	1,409794
Δ pdx _{t-5}	851,3084	Δ pdx _{t-2}	1,416177
Δ pdx _{t-6}	849,36	Δ pdx _{t-3}	1,41666

(continua)

(conclusão)			
Δpdx_{t-7}	846,4443	Δpdx_{t-4}	1,414217
Δpdx_{t-8}	841,7691	Δpdx_{t-5}	1,412568
Δpdx_{t-9}	429,4138	Δpdx_{t-6}	1,392046
$\Delta \text{nível}$	435,3449	Δpdx_{t-7}	1,356874
$\Delta \text{nível}_{t-1}$	1701,283	Δpdx_{t-8}	1,352535
$\Delta \text{nível}_{t-2}$	1956,806	$\Delta \text{nível}$	1,959452
$\Delta \text{nível}_{t-3}$	1955,671	$\Delta \text{nível}_{t-1}$	2,88937
$\Delta \text{nível}_{t-4}$	1959,412	$\Delta \text{nível}_{t-2}$	2,905026
$\Delta \text{nível}_{t-5}$	1964,463	$\Delta \text{nível}_{t-3}$	2,914472
$\Delta \text{nível}_{t-6}$	1718,342	$\Delta \text{nível}_{t-4}$	2,914562
$\Delta \text{nível}_{t-7}$	451,5878	$\Delta \text{nível}_{t-5}$	2,911472
Δtemp	4,41251	$\Delta \text{nível}_{t-6}$	2,039545
Δtemp_{t-1}	8,266239	Δtemp	1,169629
Δtemp_{t-2}	9,000667	Δtemp_{t-1}	2,435957
Δtemp_{t-3}	9,014542	Δtemp_{t-2}	2,370692
Δtemp_{t-4}	9,021142	Δtemp_{t-3}	2,280143
Δtemp_{t-5}	9,008469	Δtemp_{t-4}	2,177591
Δtemp_{t-6}	9,015877	Δtemp_{t-5}	2,027771
Δtemp_{t-7}	8,993808	Δtemp_{t-6}	1,844084
Δtemp_{t-8}	8,943636	Δtemp_{t-7}	1,63881
Δtemp_{t-9}	8,705549	Δtemp_{t-8}	1,335857
$\Delta \text{temp}_{t-10}$	4,52778	Δtemp_{t-9}	1,201985

FONTE: A autora (2016).

TABELA 17 - VALORES VIF PARA O MODELO DO SENSOR PDY

ADL original		ADL na forma de Bärdsen	
Variável	VIF	Variável	VIF
μ	NA	μ	NA
temp_{t-1}	126,1418	temp_{t-1}	1,472593
pdy_{t-1}	300,7584	pdy_{t-1}	1,028133
Δpdy_{t-1}	124,1035	Δpdy_{t-1}	1,214831
Δpdy_{t-2}	4,692901	Δpdy_{t-2}	1,201266
Δtemp	9,132447	Δtemp	1,168335
Δtemp_{t-1}	10,01105	Δtemp_{t-1}	1,34415
Δtemp_{t-2}	9,95083	Δtemp_{t-2}	1,471101
Δtemp_{t-3}	9,612735	Δtemp_{t-3}	1,492498
Δtemp_{t-4}	9,604787	Δtemp_{t-4}	1,465592
Δtemp_{t-5}	9,582641	Δtemp_{t-5}	1,374425
Δtemp_{t-6}	9,53513	Δtemp_{t-6}	1,311025
Δtemp_{t-7}	9,092817	Δtemp_{t-7}	1,172255
Δtemp_{t-8}	4,758152	Δtemp_{t-8}	1,186809

FONTE: A autora (2016).

APÊNDICE B – SCRIPT DO MATLAB

Os dois *scripts* a seguir foram utilizados para tornar diária a periodicidade dos sensores dos pêndulos, o que foi feito por meio da média das observações que tem periodicidade de 30 minutos. O *script* considerou também os dias em que houve ausência de algumas observações e os dias em que não houve observação.

```
function [mdds] = gmedias(dados)
[linha,coluna]=size(dados);
matriz = zeros(1:linha,1:4);
k=0;
n=0;
ac=0;
diain=dados(1,1);
for i=1:linha
    if dados(i,1)==diain
        ac=ac+dados(i,4);
        k=k+1;
    else
        n=n+1;
        matriz(n,1)=dados(i-1,1); %data
        matriz(n,2)=dados(i-1,2) ;%mês
        matriz(n,3)=dados(i-1,3); %ano
        matriz(n,4)=ac/k; %data
        ac=0;
        k=0;
        diain=dados(i,1);
    end
end
matriz(1:n,1:4)
mdds=size(matriz(1:n,1:4));
mdds=matriz(1:n,1:4);
mdds

function [maus] = gmedia_aus(res1)
[linha,coluna]=size(res1);
dInic=datenum(res1(1,3),res1(1,2),res1(1,1))
dFin=datenum(res1(linha,3),res1(linha,2),res1(linha,1))
dimensao=(dFin(1,1)-dInic(1,1))+1;

completa = zeros(dimensao,2);

% preenchimento de datas na matriz completa
dInic(1,1)=dInic(1,1)-1;
for i=1:dimensao
    completa(i,1)=i+dInic;
    completa(i,2)=999999;
end

% link para a matriz res1
for i=1:linha
    data=datenum(res1(i,3),res1(i,2),res1(i,1));
```

```
    posicao=data(1,1)-dInic(1,1);  
    completa(posicao,2)=res1(i,4);  
end  
completa
```


APÊNDICE C – MODELOS ARIMA E VAR

Neste apêndice segue uma descrição breve sobre os modelos ARIMA e VAR. Uma descrição detalhada dos modelos ARIMA pode ser encontrada no livro *Análise de séries temporais* de P. A. Moretin e C. M. C. Toloi de 2004 e uma descrição detalhada dos modelos VAR pode ser encontrada no livro *New introduction to multiple time series analysis* de Helmut Lütkepohl de 2005.

MODELOS ARIMA

Em estatística, ARIMA é o nome dado a um modelo muito utilizado na modelagem e previsões de séries temporais. O termo deriva do inglês *autoregressive integrated moving average*, que significa modelo autorregressivo integrado médias móveis. O modelo foi sistematizado em 1976 pelos estatísticos George Box e Gwilym Jenkins.

O modelo ARIMA é uma generalização do modelo autorregressivo médias móveis (ARMA). A representação $ARIMA(p, d, q)$ refere-se, respectivamente:

- à ordem p do modelo autorregressivo;
- à ordem d de integração e
- à ordem q do modelo médias móveis.

O modelo $ARIMA(p, d, q)$ é dado pela seguinte equação:

$$\left(1 - \sum_{i=1}^p \phi_i L^i\right) (1-L)^d X_t = \left(1 + \sum_{i=1}^q \theta_i L^i\right) \varepsilon_t$$

em que d é um inteiro positivo que determina o número de diferenças e L é o operador defasagem.

A identificação da estrutura do modelo pode ser feita por análise gráfica dos correlogramas da função de autocorrelação (FAC) e função de autocorrelação parcial (FACP). Ou, simplesmente se ajustam vários modelos e identifica-se o mais adequado por meio de um critério de informação sobre os modelos. Os critérios de informação são baseados no pressuposto de que a cada novo parâmetro adicionado no modelo, espera-se que a soma dos quadrados dos resíduos diminua, mas isto ocasionará

perda de grau de liberdade. Assim, os critérios de informação existentes aplicam determinada penalidade a cada entrada de novo parâmetro.

O critério de informação tem em geral a seguinte forma:

$$CI = \ln(\hat{\sigma}_a^2) + c \frac{F(n)}{n}$$

onde $\hat{\sigma}_a^2$ é a estimativa da variância dos resíduos, c é o número de parâmetros do modelo, n é o tamanho da série e $F(n)$ é uma função do tamanho da série. No critério AIC, por exemplo, $F(n)=2$ (CHAVES NETO, 2013).

MODELOS VAR

O modelo vetorial autorregressivo (VAR) é uma extensão de uma regressão univariada para o ambiente multivariado, onde cada equação definida pelo VAR é uma regressão por mínimos quadrados ordinários de determinada variável em variáveis defasadas de si mesma e de outras variáveis.

O modelo VAR pode ser expresso por

$$Y_t = A_0 + A_1 Y_{t-1} + \dots + A_p Y_{t-p} + B_0 X_t + B_1 X_{t-1} + \dots + B_p X_{t-p} + \varepsilon_t$$

onde A_0 é o vetor de termos de interceptos, A_1, \dots, A_p são matrizes $n \times n$ de coeficientes que relacionam valores defasados das variáveis endógenas (dependentes) e B_0, \dots, B_p são matrizes $n \times n$ que relatam valores atuais e defasados de variáveis exógenas (independentes) e ε_t é um vetor $n \times 1$ de erros.

Para selecionar o melhor modelo VAR, usam-se os critérios de informações, como por exemplo o AIC, os quais são importantes para determinar o número de defasagens a serem incluídas no modelo.

APÊNDICE D – COMANDOS NO *SOFTWARE* EVIEWS

Aqui apresentam-se os comandos do *software* Eviews na construção do modelo e na previsão. Como os comandos serão semelhantes, apenas para o sensor pix será apresentado aqui.

```
#####
ardl.ardl(deplags=12, reglags=12, trend=none) pixc nivel temp @

ardl.results

ardl.reset 2

ardl.auto(12)

ardl.resids(g)
#####
irrestrito.ls d(pixc)
c nivel(-1) temp(-1) pixc(-1) d(pixc(-1)) d(pixc(-2)) d(pixc(-3))
d(pixc(-4)) d(pixc(-5)) d(pixc(-6)) d(pixc(-7)) d(pixc(-8)) d(pixc(-9))
d(pixc(-10)) d(pixc(-11)) d(nivel) d(nivel(-1)) d(nivel(-2)) d(nivel(-3))
d(nivel(-4)) d(nivel(-5)) d(nivel(-6)) d(temp) d(temp(-1)) d(temp(-2))
d(temp(-3)) d(temp(-4)) d(temp(-5)) d(temp(-6)) d(temp(-7)) d(temp(-8))
d(temp(-9)) d(temp(-10)) d(temp(-11))

irrestrito.results

irrestrito.wald c(2)=c(3)=c(4)=0

irrestrito.wald c(4)=0
#####
longrun.ls pixc nivel temp

longrun.results

restrito.ls d(pixc) coint(-1) d(pixc(-1)) d(pixc(-2)) d(pixc(-3))
d(pixc(-4)) d(pixc(-5)) d(pixc(-6)) d(pixc(-7)) d(pixc(-8)) d(pixc(-9))
d(pixc(-10)) d(pixc(-11)) d(nivel) d(nivel(-1)) d(nivel(-2)) d(nivel(-3))
d(nivel(-4)) d(nivel(-5)) d(nivel(-6)) d(temp) d(temp(-1)) d(temp(-2))
d(temp(-3)) d(temp(-4)) d(temp(-5)) d(temp(-6)) d(temp(-7)) d(temp(-8))
d(temp(-9)) d(temp(-10)) d(temp(-11))

restrito.results

restrito.reset 2

restrito.auto(5)
#####
irrestrito.results
smpl 10/01/2015 11/30/2015
irrestrito.forecast(f=na, e, g) pixcf
smpl 10/27/2005 11/30/2015
#####
restrito.results
smpl 10/01/2015 11/30/2015
restrito.forecast(f=na, e, g) pixcf
smpl 10/27/2005 11/30/2015
```

```
#####
var.representations
var.ls 1 2 d(pixc) nivel temp

var_ols.ls d(pixc) d(pixc(-1)) d(pixc(-2)) nivel(-1) nivel(-2) temp(-1)
temp(-2)

var_ols.results
smpl 10/01/2015 11/30/2015
var_ols.forecast(f=na, e, g) pixcf
smpl 10/27/2005 11/30/2015
#####
pixc.sheet
pixc.autoarma(tform=none) pixc_f01 c

arima23.ls(optmethod=opg) d(pixc) ar(1) ar(2) ma(1) ma(2) ma(3)
arima23.results

smpl 10/01/2015 11/30/2015
arima23.forecast(f=na, e, g) pixcf
smpl 10/27/2005 11/30/2015
#####
```


APÊNDICE E – MOVIMENTOS NO BLOCO DE CONCRETO À GRAVIDADE

Trata-se agora, de maneira simplificada, como ocorrem os movimentos de um bloco de concreto à gravidade.

As verificações necessárias em barragens de concreto à gravidade (maciça ou aliviada), no sentido de avaliar a segurança global, são em relação aos seguintes movimentos: deslizamentos (na estrutura ou na fundação); tombamento; flutuação; tensões (na base da fundação e na estrutura); deformações (recalques) e vibrações (KRÜGER, 2008).

Segundo Villwock (2009), algumas condições de carregamento básicas podem provocar o deslizamento e/ou tombamento de um bloco de concreto à gravidade (Figura 29).

FIGURA 29 - DESLIZAMENTO E TOMBAMENTO EM UM BLOCO DE CONCRETO À GRAVIDADE




FONTE: Villwock (2009).

A autora explica como esses movimentos podem ocorrer devido a um desequilíbrio entre forças estabilizadoras e desestabilizadoras. A diferença de nível de água (montante-jusante) gera um gradiente hidráulico que faz com que a água tente se deslocar a jusante buscando o equilíbrio hidráulico. Isso ocorre por percolação através do maciço de fundação da barragem. Neste processo, a água infiltrada gera forças verticais que atuam de baixo para cima sob a barragem, denominadas subpressões na fundação. A resultante destas forças denomina-se por $F_{\text{subpressão}}$. Tem-se também as pressões hidrostáticas contra a parede da barragem

que atuam na direção montante/jusante, representada por $F_{\text{reservatório}}$ a resultante destas forças. Estas forças são denominadas forças desestabilizadoras e a força peso P (o peso próprio da barragem) é uma força estabilizadora da estrutura.

Um bloco de concreto à gravidade ainda está sujeito à expansão e à contração do concreto resultantes das variações sazonais da temperatura ambiente. Segundo Osako (2002), no verão ocorre uma dilatação no concreto, que provoca o movimento do bloco para montante gerando uma compressão na fundação. No inverno o concreto se contrai, provocando um movimento do bloco para jusante, tendendo à posição inicial. Assim, ocorre um alívio na pressão sobre a fundação que ocorreu no verão (Figura 30).

FIGURA 30 - VARIAÇÃO SAZONAL EM UM BLOCO DE CONCRETO À GRAVIDADE



FONTE: Osako (2002).